

Tesis Doctoral.

Programa de Doctorado en Ingeniería y Arquitectura.


Universidad Pública de Navarra.

Clasificación de cultivos a partir de observaciones de teledetección radar.

Aplicación a zonas de secano y regadío de Navarra.

Presentada por:
Arantzazu Larrañaga Urien

Dirigida por:
Dr. Jesús Álvarez Mozos



Agradecimientos

En primer lugar, me gustaría reconocer la labor de mi tutor. Txus, gracias por ayudarme en TODO y sobre todo por animarme este último año para que este trabajo saliera adelante. Estoy segura de que todo esto, no hubiese sido posible sin tu ayuda, eskerrik asko! Gracias también a Lourdes, para mí has sido como mi segunda tutora. Tus consejos han sido siempre útiles para mejorar el trabajo.

También tengo que agradecer a Tracasa, por confiar en mí y haberme dado la oportunidad de desarrollar gran parte de este trabajo con ell@s. Gracias a tod@s las compañer@s de trabajo por vuestro apoyo. No cito a nadie, puesto que sois much@s y seguro que se me escapa algún@... Cada un@ de vosotr@s habéis aportado algo en este trabajo.

A mis amigas, por escucharme, aguantarme... y como no, por animarme en todo momento.

Por último y no menos importante, quería agradecer a mi familia, en especial a mis padres por su incondicional ayuda de todo tipo y como no, a Patxi y a mis dos “enanas” Ane y Aloña, los verdaderos “sufridores” de esta tesis. Vuestro apoyo no tiene precio!

Gracias a tod@s por haber estado a mi lado en los buenos y en los “no tan buenos” momentos.

Índice General

ABSTRACT

RESUMEN

PREFACIO

1. Introducción	15
2. Desarrollo del trabajo.....	18
2.1. Zona de estudio e imágenes utilizadas	18
2.2. Metodologías	23
2.2.1. Procesamiento de las imágenes.....	23
2.2.2. Análisis de los datos	28
2.2.3. Algoritmos de clasificación.....	29
3. Presentación de los trabajos	34
4. Discusión y conclusión general	113
Apéndice.....	117
Referencias.....	119

ABSTRACT

Remote sensing consists of acquiring information of a specific object or area through observation sensors. Crop classification is one of the major agricultural applications of remote sensing. Since the launch, in 1972, of the first satellite for the assessment natural resources, Landsat-1, many works have been carried out in this field. All these early works were based on multispectral optical remote sensing systems, where the main limitation of this technology was the cloud cover. Synthetic aperture radar (SAR) sensors provide an interesting alternative. SAR sensors can acquire data regardless of cloud cover and in the absence of sunlight, increasing the probability of obtaining useful data over a certain area and time period of interest; and thus, providing the possibility of dynamic classifications over a full crop year, and even detecting rotations of several crops in a year. Furthermore, the response recorded by SAR sensors is related to the geometrical and dielectric properties of the crops and exhibit an adequate spatial and temporal resolution for this type of applications.

The main objective of this thesis is to develop suitable techniques and tools for crop classification through the use of SAR observations. In addition, the results obtained by these techniques are compared with those obtained by conventional methods based on optical sensors in order to assess the feasibility of these SAR observations for classification schemes. All this is collected throughout the four articles and one report presented in this thesis.

The study site was located in Central Navarre, where agricultural areas are mainly intended for rain-fed herbaceous crops. The available data set comprised optical and SAR imagery. The ancillary data used consisted of basic geospatial information and CAP declarations and ground truth data resulting from the inspections of the EU CAP (European Common Agricultural Policy subsidies) program of the studied years. After processing the images, a number of polarimetric features of interest have been extracted. All these data have been analyzed graphically and numerically prior to classification. In the graphic analysis, observations have been interpreted in terms of morphology, configuration and characteristics of the different vegetation covers. In the numerical analysis, separability or statistical dissimilarity between crops for different features and dates have been assessed in order to select the most interesting ones. Although at first the normalized distance has been used as a separability measure, the Jeffries-Matusita distance has been preferred in the rest of the work. Regarding the classification algorithms, in the initial works conventional classification algorithms (Maximum Likelihood and Mahalanobis) have been used, but later the Random Forests (RF) classification algorithm has been chosen to use as it is more versatile and powerful.

The results obtained demonstrate that the multitemporality and the acquisition date of images are more important issues for crop identification and classification than their polarimetric information. Indeed, multi-temporal dual-pol configuration radar data have provided good results, similar to those achieved in quad-pol polarization, with an overall accuracy of 79% and a Kappa value of 0.69. The inclusion of different polarimetric features, particularly $|\rho_{HHVV}|$ and ϕ_{HHVV} , improved the overall accuracy. However, at the crop level, major crops such as cereals, rapeseed and sunflower have also achieved a good accuracy using only dual-pol data, and the improvements observed in these cases have been minor. The most interesting polarization channel for crop classification has been HV and with respect to the wavelength of the sensor, the C-band has achieved the best results. On the other hand, the accuracy obtained in classifications based on optical images has increased when SAR data have been included in a multispectral classification scheme, being demonstrated that the additional information provided by these sensors can be useful. Among all the analyzed classification algorithms, the RF classifier has been the most efficient, although it produces weak results when learning from heavily imbalanced training datasets. In this sense, it has been found that including a method for balancing the size of the training datasets of each crop (avoiding very small samples) has improved the final classification accuracy.

All in all, the results obtained have demonstrated that SAR data can be effectively used for crop classification. Therefore, it is expected that this work encourages the adoption of such tools between technicians and potential users, resulting in the development of operational applications of great value. This is especially true given the current context of the Copernicus program of the European Union, where Sentinel-1 scenes, with optimal characteristics for this type of application, can be accessed free of charge.

RESUMEN

La teledetección consiste en adquirir a través de sensores de observación, información de un objeto concreto o un área. Una de las principales aplicaciones de la teledetección en el ámbito agrícola es la clasificación de cultivos. Desde el lanzamiento, en 1972, del primer satélite de evaluación de recursos naturales Landsat-1 se han realizado múltiples trabajos en este campo. Todos estos trabajos iniciales se basaban en observaciones adquiridas por sensores ópticos multiespectrales, donde la principal limitación para el uso de esas imágenes ópticas era la cubierta nubosa. Los sensores radar representan una alternativa interesante. Una de las principales ventajas de dicha tecnología frente a la teledetección óptica es la absoluta independencia del estado de cobertura nubosa para la adquisición de las imágenes, lo que brinda la posibilidad de hacer clasificaciones dinámicas a lo largo de un año agrícola completo, pudiendo representar incluso rotaciones de varios cultivos en un año. Además, los sensores radar son sensibles a características geométricas y dieléctricas de los cultivos, y presentan una resolución tanto espacial como temporal adecuada para este tipo de aplicaciones.

El principal objetivo de esta Tesis es desarrollar técnicas y herramientas adecuadas para la clasificación de cultivos mediante el empleo de observaciones de teledetección radar. Además, se comparan los resultados obtenidos mediante estas técnicas con los obtenidos por procedimientos clásicos basados en sensores ópticos con la finalidad de evaluar la viabilidad de la teledetección radar para este tipo de aplicaciones. Todo esto, se recoge a lo largo de los cuatro artículos y un informe que componen esta tesis.

El estudio se ha llevado a cabo en la zona media de Navarra, donde las zonas agrícolas se destinan principalmente a cultivos herbáceos de secano. La serie de imágenes utilizadas, ha procedido de sensores tanto ópticos como radar. Como información auxiliar, se ha contado con información geoespacial básica y con datos de las declaraciones e inspecciones de la PAC (Política Agraria Común) de los años estudiados. Tras procesar las imágenes, se han obtenido una serie de bandas derivadas de interés, cuyos datos se han analizado de forma gráfica y numérica previamente a la clasificación. En el análisis gráfico se han interpretado las observaciones en términos de morfología, configuración y características de las diferentes cubiertas. En el análisis numérico se ha evaluado la separabilidad, o disimilitud estadística entre los cultivos, para los diferentes parámetros y fechas, con el fin de seleccionar los parámetros más significativos. Si bien al principio se ha utilizado la distancia normalizada, posteriormente, se ha optado por utilizar la distancia de Jeffries-Matusita (JM). En cuanto a los algoritmos de clasificación, en los trabajos iniciales se han utilizado algoritmos de clasificación

convencionales (Máxima Verosimilitud y Mahalanobis) y más adelante, se ha optado por utilizar el algoritmo de clasificación Random Forests (RF) ya que es más versátil y potente.

Los resultados obtenidos demuestran que la multitemporalidad y la fecha de adquisición de imágenes son características más importantes incluso que su información polarimétrica a la hora de identificar correctamente los cultivos. Efectivamente, las imágenes radar multitemporales de configuración dual-pol han proporcionado buenos resultados y similares a los alcanzados en polarización cuádruple, fiabilidad global del 79% y un coeficiente de Kappa de 0.69. La inclusión de otras bandas polarimétricas derivadas, en particular $|\rho_{HHVV}|$ y ϕ_{HHVV} , han mejorado sensiblemente los resultados globales, sin embargo, a nivel de cultivo, los cultivos mayoritarios como los cereales, colza y girasol, han obtenido también una buena fiabilidad utilizando únicamente datos dual-pol y las mejoras observadas en estos casos han sido menores. El canal de polarización más interesante para la clasificación de los cultivos ha sido el HV y respecto a la longitud de onda del sensor, la banda-C ha sido la que mejores resultados ha proporcionado. Por otro lado, la fiabilidad de las clasificaciones ha mejorado en los casos donde se ha combinado una imagen óptica con escenas radar, quedando demostrado así que la información complementaria que aportan estos sensores puede ser de utilidad. Entre todos los algoritmos de clasificación analizados, el clasificador RF ha sido el más eficiente, aunque resulte sensible a problemas de clasificación desequilibrados. En este sentido, se ha comprobado que incorporar un procedimiento para equilibrar el tamaño de las áreas de entrenamiento de cada cultivo (evitando trabajar con muestras muy pequeñas) ha favorecido la fiabilidad de la clasificación final.

Con todo, los resultados obtenidos han demostrado la viabilidad de la teledetección radar para la clasificación de los cultivos estudiados. Por lo tanto, se espera que este trabajo fomente la adopción de este tipo de herramientas entre técnicos y usuarios potenciales, lo que permitiría desarrollar aplicaciones operativas de gran valor. Más aún si cabe, en el contexto actual del programa Copernicus de la Unión Europea, que distribuye de forma libre imágenes radar Sentinel-1 con unas características óptimas para este tipo de aplicaciones.

PREFACIO

Esta Tesis Doctoral se presenta dentro del extinto Programa de Doctorado en Ingeniería y Arquitectura de la Universidad Pública de Navarra (UPNA). El trabajo ha sido realizado, en parte, gracias a la financiación del subprograma Torres Quevedo del antiguo Ministerio de Ciencia e Innovación, al Fondo Social Europeo, al Proyecto CGL2007-63453/HID del Plan Nacional de I+D+i y al Proyecto SOAR-EU 6774 de las Agencias Espaciales Europea y Canadiense (ESA-CSA).

La Tesis Doctoral que se presenta es un compendio de cuatro artículos y un informe. Los artículos han sido ya publicados Larrañaga et al., (2010; 2011a; 2013) y Larrañaga y Álvarez-Mozos (2016). En cuanto al informe (Larrañaga et al., 2011b), consiste en un trabajo encargado por el Gobierno de Navarra a Tracasa¹ en 2010 y realizado como parte de la tesis de la doctoranda. Las referencias completas de dichos trabajos son:

- Larrañaga, A., Albizua, L. y Álvarez-Mozos J. 2010. Clasificación de cultivos en la zona media de Navarra mediante imágenes radar polarimétricas. *Revista de Teledetección*, 34, 77–88.
- Larrañaga, A., Álvarez-Mozos, J. y Albizua, L. 2011a. Crop classification in rain-fed and irrigated agricultural areas using Landsat TM and ALOS / PALSAR data. *Canadian Journal of Remote Sensing*, 37(1), 157-170.
- Larrañaga, A., Albizua, L. y Álvarez-Mozos, J. 2011b. *Evaluación de la viabilidad del empleo de imágenes radar multitemporales de configuración simple y de la combinación radar-óptico para la clasificación de los cultivos de secano*. Informe no publicado. Departamento de Desarrollo Rural, Agricultura y Administración Local, Gobierno de Navarra, Pamplona, España, 15 pp.
- Larrañaga, A., Álvarez-Mozos, J., Albizua, L. y Peters J. 2013. Backscattering behavior of rain-fed crops along the growing season. *IEEE Geoscience and Remote Sensing Letters*, 10(2), 386–390.
- Larrañaga, A. y Álvarez-Mozos, J., 2016. On the added value of Quad-Pol data in a multi-temporal crop classification framework based on RADARSAT-2 imagery. *Remote Sensing*, vol. 8(4), 335.

Siguiendo lo indicado en la normativa, este documento se estructura del siguiente modo. En primer lugar se incluye una introducción general sobre el tema de tesis, donde se revisa el estado del arte y se enuncian los objetivos planteados. A continuación se describe la zona de estudio y la metodología seguida para llevar a cabo el trabajo. Luego se presentan los trabajos que forman el cuerpo de la tesis, en el formato en el que fueron publicados. Finalmente se concluye con una discusión y conclusión general. Es necesario destacar que los apartados de introducción, metodología y discusión y conclusión general se han redactado de forma resumida, tratando en la medida de lo posible de evitar ser redundantes con lo escrito en los trabajos publicados.

¹ Empresa pública especializada en la prestación de servicios basados en el uso de la información territorial y las tecnologías de la información y las telecomunicaciones, tanto para las administraciones públicas como privadas.

A Ane y Aloña.

“Si caminas solo llegarás más rápido, pero si lo haces acompañado llegarás más lejos”

(Proverbio chino)

1. Introducción

La sostenibilidad de los sistemas agrarios y el control y la conservación del medio exigen integrar criterios medioambientales en el mundo agrícola. Estas exigencias se manifestaron a nivel Europeo en las normas Agenda 2000 y Red Natura 2000, vigentes a día de hoy. En zonas (semi)áridas como las de la cuenca mediterránea donde se alternan cultivos de secano y regadío, este hecho adquiere especial relevancia. La transformación de terrenos de agricultura de secano a regadío puede generar cambios ambientales, impactos sobre los recursos hídricos o controversias sobre el uso del agua y el manejo de la tierra. Una gestión adecuada del territorio requiere de información precisa y actualizada sobre los cultivos implantados en cada parcela. Esta información es clave para gestionar la producción agrícola y prever producciones a escala local (Boryan et al., 2011), pero también representa una información vital para la toma de decisiones en ámbitos como el diseño de políticas agrarias o la gestión de subsidios agrícolas (Schmedtmann y Campagnolo, 2015).

Los métodos convencionales de obtención de datos del territorio se basan, en general, en trabajos de campo, siempre costosos y lentos (Chuvieco, 2002). La teledetección puede facilitar esta labor, disminuyendo el esfuerzo necesario para obtener un mapa de cultivos y, por ende, su coste total.

El uso de la teledetección para la clasificación de cultivos no es algo nuevo. Desde el lanzamiento, en 1972, del primer satélite de evaluación de recursos naturales Landsat-1 se han realizado múltiples trabajos en este campo (e.g., Barbosa et al., 1996; Franklin y Wulder, 2002; Gallego, 2004; Gieske et al., 2006; Conrad et al., 2010; Tatsumi et al., 2015). Los primeros trabajos se basaban en observaciones adquiridas por sensores ópticos multispectrales. Estos sensores captan la energía procedente del sol que reflejan las diferentes cubiertas a distintos intervalos (bandas) de longitud de onda. Dichas observaciones se integraban generalmente en algoritmos de clasificación supervisada en los que se contaba con una muestra de referencia (áreas de entrenamiento) de los diferentes cultivos que servía para asignar una parcela a una clase u otra en base a su parecido (medido mediante diferentes estadísticos) (Chuvieco, 2002).

En el caso concreto de Navarra las técnicas de clasificación supervisada de imágenes multispectrales de satélite se incorporaron al proceso de elaboración de Estadísticas Agrarias Oficiales en 1991. Se vio que la fiabilidad de las clasificaciones obtenidas variaba de forma dramática en función del número de imágenes y de su fecha de adquisición (Leránz y Albizua, 1998). Es importante conocer el calendario agronómico de los cultivos y adquirir imágenes en periodos en los que las diferencias entre ellos sean más apreciables. Si a esta limitación se le añade la influencia de la cubierta nubosa, que limita e incluso imposibilita el uso de las imágenes ópticas de teledetección, la técnica puede resultar, debido a la escasez de imágenes, en clasificaciones cuya fiabilidad no alcance los requerimientos mínimos.

Una alternativa al uso de imágenes ópticas multispectrales es el empleo de imágenes adquiridas por sensores radar (Skriver, 2012). Los sensores de teledetección radar son sensores activos que trabajan en la región del espectro electromagnético de las microondas (longitudes de onda centimétricas). Como tales, emiten un pulso de radiación hacia la superficie terrestre y captan la señal de retorno procedente de las cubiertas del terreno. El

pulso de radiación emitido interactúa con la superficie y experimenta una serie de procesos de dispersión y reflexión dependiendo de la naturaleza de la cubierta observada (Ulaby et al., 1986). Una de las principales ventajas de estos sensores es que la cubierta nubosa no limita su capacidad de observación. A las longitudes de onda que trabajan estos sensores la cobertura nubosa es transparente, por lo que la nubosidad no supone ningún tipo de limitación en este caso. Por otro lado, al ser sensores activos pueden funcionar independientemente de la radiación solar incidente, incluso en condiciones de oscuridad, lo cual aumenta su capacidad de funcionamiento en comparación con la de los sensores ópticos.

La resolución espacial de los sensores radar es adecuada para realizar clasificaciones de cultivos. Los primeros satélites radar incorporaban sensores de apertura sintética (SAR) que proporcionaban ya resoluciones del orden de 20-30 m. No obstante, los sensores SAR más modernos logran resoluciones mucho mayores, de 1 m en determinados modos de operación (Spotlight) de RADARSAT-2, TerraSAR-X o COSMO-SkyMed.

La señal de retorno que capta el sensor permite calcular el coeficiente de retrodispersión (σ°), magnitud física que representa el ratio entre el pulso de radiación retornado y el inicialmente emitido, que depende de las características de las cubiertas observadas y de la configuración del propio sensor (Ulaby et al., 1986). Los parámetros principales de la configuración de un sensor son la frecuencia, o longitud de onda, de la radiación que emite y recibe (denominada banda), el ángulo de incidencia que forma el haz de radiación emitido con la normal del terreno y la polarización de la radiación emitida y recibida por el sensor. La polarización hace referencia a la orientación del campo eléctrico de la radiación electromagnética. Tradicionalmente se ha trabajado con dos polarizaciones: la vertical (V) y la horizontal (H), por lo tanto un sensor que emite y recibe en la polarización H se denomina “de polarización HH”, mientras que uno que emite en V y recibe en H se denomina “de polarización VH”.

Los parámetros mencionados determinan el tipo de interacción que se produce con las cubiertas observadas. En el caso de la frecuencia, a mayor frecuencia la interacción se produce con los elementos más pequeños de las cubiertas (por ejemplo hojas o frutos), mientras que a frecuencias bajas la radiación penetra en las cubiertas y ofrece información de tallos y troncos o incluso de la superficie del suelo. La mayoría de los sensores SAR actuales operan en la banda-C (~5 GHz) (RADARSAT-1 y -2, Sentinel-1A, RISAT-1), pero también los hay que operan en la banda-L (~1 GHz) (ALOS-1 y 2/PALSAR) y banda-X (~10 GHz) (TerraSAR-X y COSMO-SkyMed). El ángulo de incidencia también tiene una gran importancia, ya que con ángulos de incidencia elevados (tendidos) se favorece la interacción con la vegetación, mientras que con ángulos menores (ceranos a la vertical) la radiación penetra más fácilmente en las cubiertas. Existen tres principales mecanismos de retrodispersión: superficial (*surface scattering*), de doble rebote (*double bounce*) y de volumen. En terrenos homogéneos como cuerpos de agua y suelos desnudos, predomina la retrodispersión de superficie frente a la de volumen, dependiendo de la frecuencia de la onda y rugosidad del terreno. Por el contrario, en terrenos heterogéneos como por ejemplo zonas de vegetación densa, predomina la retrodispersión de volumen. Por último, la retrodispersión de doble rebote, ocurre en superficies contiguas que forman ángulos rectos como por ejemplo, áreas urbanas, árboles rodeados por agua y barcos en el mar. La preponderancia de un mecanismo de retrodispersión u otro depende también de su capacidad de penetración en la cubierta observada, que está condicionada por la longitud

de onda de la observación y su ángulo de incidencia. De modo que longitudes de onda largas y ángulos de incidencia pequeños favorecen la penetración en las cubiertas vegetales, llegando a proporcionar información sobre la superficie subyacente. Por otro lado, las distintas polarizaciones (HH, HV, VH, VV), muestran una sensibilidad diferente en relación con las características de las diferentes superficies de terreno. La polarización HH, resulta más sensible al fenómeno de retrodispersión superficial y por lo tanto se ve menos afectada por la cubierta vegetal. Las polarizaciones HV y VV en cambio, presentan una mayor sensibilidad a la dispersión por volumen y son más adecuadas para los casos donde interesa estudiar o considerar la vegetación (Ulaby et al., 1986).

Los primeros sensores que se lanzaron en los años 90 (ERS-1 y -2, JERS-1 y RADARSAT-1) trabajaban en una única banda (banda-C), con una única polarización (generalmente directa, HH o VV) y con un único ángulo de incidencia (salvo en el caso de RADARSAT-1). En consecuencia, estos sensores proporcionaban un único canal de información por cada imagen adquirida, al contrario de lo que ocurre por ejemplo con los sensores ópticos multispectrales. Esto supuso una limitación de cara a su uso en clasificaciones de cubiertas. Esta limitación se superó en parte mediante el uso de series de imágenes multitemporales (Bouman y Uenk, 1992), aunque los resultados obtenidos en estos casos tampoco fueron comparables a los obtenidos mediante sensores ópticos multispectrales (Saich y Borgeaud, 2000; Waske y Braun, 2009; McNairn, 2009).

Los sensores radar más modernos (ENVISAT/ASAR, ALOS-1/PALSAR, RADARSAT-2, TerraSAR-X o COSMO-SkyMed o los recién estrenados Sentinel-1A y ALOS-2/PALSAR) incorporan la capacidad de adquirir información en polarizaciones múltiples, es decir, son capaces de emitir y recibir radiación en varias polarizaciones. Algunos de ellos operan en polarización dual (normalmente VV-VH, HH-HV) y otros en cuádruple (HH-HV-VH-VV), también denominado quad-pol o modo polarimétrico. La adquisición simultánea de imágenes en varias polarizaciones puede resultar beneficiosa dado que se añaden canales de información adicional interesante para interpretar y clasificar las observaciones, de forma análoga a las imágenes ópticas multispectrales. Además, los sensores con capacidades polarimétricas o quad-pol permiten extraer otro tipo de parámetros, parámetros (*features*) polarimétricos (ver 2.2.1. *Procesamiento de las imágenes*) que pueden resultar de gran interés para la interpretación y clasificación de las cubiertas (Skriver, 2012). Sin embargo, hay que tener en cuenta que estos sensores quad-pol también presentan una serie de inconvenientes: son más complejos, almacenan grandes volúmenes de datos y por tanto ofrecen una cobertura pequeña y un tiempo de revisita más largo. Por todo ello, es importante evaluar el valor añadido que aportan estas observaciones polarimétricas a diferentes aplicaciones y en especial a las clasificaciones de cultivos.

El objetivo principal de esta Tesis Doctoral ha sido investigar y desarrollar técnicas y herramientas para la clasificación de cultivos mediante el empleo de observaciones de teledetección radar. Asimismo, se han comparado los resultados obtenidos mediante estas técnicas con los obtenidos por procedimientos clásicos basados en sensores ópticos multispectrales para evaluar la viabilidad de la teledetección radar para estas aplicaciones.

Partiendo de esta generalidad, hay una serie de aspectos concretos que se han estudiado e investigado y que se pueden sintetizar en los siguientes objetivos específicos:

1. Evaluar algoritmos de clasificación basados en observaciones radar multitemporales de configuración simple.
2. Analizar distintos clasificadores supervisados para realizar clasificaciones a nivel de objeto de imágenes multitemporales.
3. Evaluar procedimientos para el uso combinado de imágenes radar polarimétricas y ópticas, aprovechando las ventajas de cada una de las técnicas y su complementariedad.
4. Determinar qué canales de polarización resultan más interesantes de cara a la clasificación y de cuales se puede prescindir.
5. Calcular diferentes parámetros polarimétricos y evaluar su importancia de cara a la clasificación de cultivos.
6. Estudiar la influencia del número de imágenes adquiridas y de su momento de adquisición en los resultados de las clasificaciones.

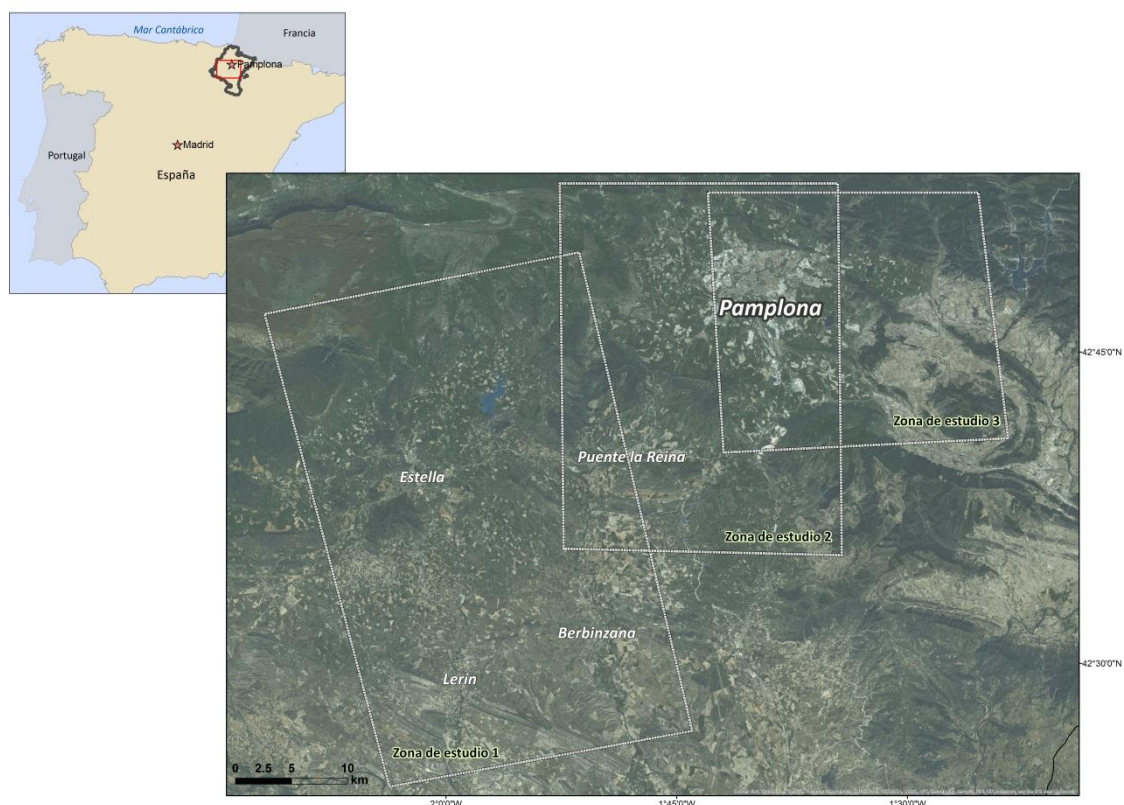
2. Desarrollo del trabajo

2.1. Zona de estudio e imágenes utilizadas

El estudio se llevó a cabo en la zona media de la Comunidad Foral de Navarra (Figura 1). Las zonas agrícolas de interés estaban ocupadas por cultivos herbáceos de secano y de regadío, siendo mayoritarios los primeros. En las campañas agrícolas estudiadas, el cultivo predominante fue el cereal de secano, principalmente el trigo. El resto de cultivos estudiados fueron la avena y la cebada, alfalfa, espárragos, guisante, girasol, veza, colza, pastos y barbecho. Los cultivos minoritarios variaron ligeramente en función del área de estudio de cada trabajo. Tal y como se acaba de mencionar, la zona de estudio general se situó en la zona media de Navarra, sin embargo, la zona exacta utilizada en cada trabajo, varió en función de la cobertura de las imágenes utilizadas (Figura 1).

El relieve de las zonas de estudio se puede considerar bastante homogéneo. Si bien las elevaciones varían entre 480 y 1084 m, las zonas agrícolas que se estudiaron se encuentran situadas en los valles y zonas más bajas y con pendientes, en general, muy pequeñas. El tamaño de las parcelas fue bastante variable, aunque la mayoría de ellas oscilaban entre 2 y 5 has, siendo en general, las parcelas de regadío algo más pequeñas.

Como información auxiliar, se contó con: (i) un Modelo Digital de terreno (MDT) de 5 m de resolución de toda Navarra, (ii) información de las declaraciones de la PAC (Política Agraria Común) de los años estudiados, (iii) información de campo correspondiente a las inspecciones de las declaraciones de la PAC de los años estudiados que se utilizan como verdad campo y (iv) calendario agronómico de los cultivos a clasificar (Figura 2).































Zona de estudio 1: Larrañaga et al., 2010; Larrañaga et al., 2011a

Zona de estudio 2: Larrañaga et al., 2011b

Zona de estudio 3: Larrañaga et al., 2013; Larrañaga y Álvarez-Mozos, 2016

Figura 1. Área de estudio indicando las tres zonas concretas estudiadas en las distintas publicaciones.

			Calendario agronómico											
Cultivo	S ¹	R ²	I	II	III	IV	V	VI	VII	VIII	IX	X	XI	XII
Cebada	✓	✓												
Trigo	✓	✓												
Avena	✓													
Alfalfa	✓	✓												
Haba	✓	✓												
Girasol	✓	✓												
Colza	✓													
Espárrago	✓													
Guisante	✓	✓												
Veza	✓													
			<div><div> Sembrado</div><div> Cosechado</div></div>											
<div><div>1 secano</div><div>2 regadío</div></div>														

¹ secano

² regadío

■ Sembrado

■ Cosechado

Figura 2. Calendario agronómico de los cultivos clasificados. (Adaptado de: INTIA, antes ITGA)

Las declaraciones de la PAC se encuentran disponibles en el Sistema de Información Geográfica para la PAC (SIGPAC), que es un archivo vectorial actualizado, en Navarra, anualmente por Tracasa con información detallada de los usos declarados de cada parcela y que garantiza un ajuste muy preciso de la superficie agrícola (<http://sigpac.navarra.es>). El SIGPAC se trata de una información elaborada a escala 1:5,000 y se considera la mejor referencia de superficies de los distintos estratos agrícolas: herbáceos, viñas, olivos, frutales y frutos secos tanto de secano como de regadío. Del SIGPAC se obtuvieron los objetos (recintos) a partir de los cuales se estratificaron las parcelas agrícolas, se tomó la verdad campo y se clasificaron las imágenes de satélite utilizadas. Cabe destacar que para cada trabajo se partió de la versión más actual del SIGPAC, centrándonos en los estratos agrícolas de herbáceos de secano y de regadío.

Las inspecciones de las declaraciones PAC resultaron ser una fuente de información clave para la obtención de las firmas o firmas de cada cultivo así como para la validación de las clasificaciones. Aproximadamente 2/3 de las parcelas de verdad campo de las que se disponía se utilizaron como áreas de entrenamiento o “*training sets*”, mientras que el 1/3 restante se utilizó como áreas de validación “*test sets*”, para obtener los estadísticos necesarios para validar y medir la fiabilidad o bondad de las clasificaciones. La asignación de las parcelas de campo a “*training sets*” o “*test sets*” se realizó de forma semi-dirigida, poniendo especial atención en obtener una muestra representativa de cada cultivo tanto para la fase de entrenamiento como para la de validación. La Figura 3 muestra un ejemplo de cómo se ha dividido la verdad campo.



Figura 3. Ejemplo de las parcelas utilizadas como *training* (en amarillo) y *test* (en azul) sets en Larrañaga et al. (2013) y Larrañaga y Álvarez-Mozos (2016).

La serie de imágenes de satélite utilizadas procedió de distintos sensores, tanto ópticos como radar. Las tablas 1-3 recogen los sensores utilizados en cada trabajo y resumen las principales características de cada uno de ellos.

Tabla 1. Relación de los sensores utilizados en cada uno de los trabajos presentados.

Tipo	Satélite/Sensor	Fecha	Trabajos que componen la tesis				
			Larrañaga et al., 2010	Larrañaga et al., 2011a	Larrañaga et al., 2011b	Larrañaga et al., 2013	Larrañaga y Álvarez-Mozos, 2016
Óptico	Landsat 5-TM	11/08/2007		✓			
		25/05/2009			✓		
		13/06/2009			✓		
		31/07/2009			✓		
Radar	ERS-2/AMI	29/04/2009			✓		
		18/05/2009			✓		
		16/06/2009			✓		
		27/07/2009			✓		
	ENVISAT/ASAR	03/06/2009			✓		
	ALOS-1/PALSAR	25/03/2007	✓	✓			
		10/05/2007	✓	✓			
	RADARSAT-2/SAR	29/03/2010				✓	
		18/04/2010				✓	
		12/05/2010				✓	✓
		05/06/2010				✓	✓
		29/06/2010				✓	✓

Tabla 2. Características del sensor óptico utilizado.

Satélite	Fecha	Bandas	% nubes	Ancho (km)	Revisita	Resolución (m)
Landsat 5	11/08/2007 25/05/2009 13/06/2009 31/07/2009	Multiespectral: Banda 1, azul : 0.45-0.52 μm Banda 2, verde : 0.52-0.60 μm Banda 3, rojo : 0.63-0.69 μm Banda 4, IR cercano : 0.76-0.90 μm Banda 5, IR cercano : 1.55-1.75 μm Banda 7, IR medio : 2.08-2.35 μm Térmico: Banda 6, IR térmico : 10.4-12.5 μm	0	185	16	30 (Multi.) 120 (Térmico)

Tabla 3. Características de los sensores radar utilizados.

Satélite	Fecha	Modo	Nivel de proces.	Banda	Pol.	Áng. inc.	Ancho (km)	Revisita	Resolución (m) (RnxAz)
ERS-2	29/04/2009 18/05/2009 16/06/2009 27/07/2009	Stripmap	Level 1.5 (PRI)	C / 5.3 GHz	VV	23°	100	35	25x25
ENVISAT	03/06/2009	Stripmap	Level 1.5 (PRI)	C / 5.3 GHz	VV	23°	105	35	30x30
ALOS-1	25/03/2007 10/05/2007	Quad-pol	Level 1.1 (SLC)	L / 1.27 GHz	HH-HV- VH-VV	24°	35	46	30x30
RADARSAT-2	29/03/2010 18/04/2010	Estandar Quad-pol	Level 1.1 (SLC)	C / 5.3 GHz	HH-HV- VH-VV	30°	25	26	9.0-13.5x8.0
	12/05/2010 05/06/2010 29/06/2010	Fino Quad-pol	Level 1.1 (SLC)			30°	25	26	5.4x8.0

PRI: Imagen de precisión. Es una imagen de varias observaciones (*multi-look*), proyectada sobre el terreno (*ground range*).

SLC: Imagen compleja, además de la amplitud preserva también la fase, de una sola observación (*Single Look Complex*). La imagen se distribuye en la dirección del alcance (*slant range*), sin proyectar sobre el terreno.

Fuente: "SAR image processing levels" https://earth.esa.int/c/document_library/get_file?folderId=226458&name=DLFE-2126.pdf

Tal y como se detalla en la Tabla 2, las imágenes ópticas utilizadas procedieron del satélite **Landsat 5**. Este satélite fue puesto en órbita en marzo de 1984 y estuvo operativo hasta enero de 2013. Ha sido uno de los satélites ópticos más empleados en aplicaciones de teledetección orientadas al ámbito rural y forestal, centradas en la identificación y clasificación de las distintas cubiertas, así como en estudios multitemporales. El sensor TM (*Thematic Mapper*) disponía de lectura en 7 bandas situadas en distintas zonas del espectro electromagnético (desde el visible hasta el infrarrojo térmico), con una resolución espacial de 30 m para todas las bandas excepto para la banda 6 (térmica), de 120 m (esta última banda no se ha utilizado en este trabajo).

Las imágenes radar empleadas proceden de distintos satélites. **ERS-2 y ENVISAT (ENvironmental SATellite)** pertenecieron a la Agencia Espacial Europea (ESA) y se lanzaron en el año 1995 y 2002 respectivamente. A día de hoy ninguno de los dos sigue operativo, pero estuvieron funcionando hasta septiembre del 2011 y abril del 2012 respectivamente. Los dos trabajaban en la banda-C (5.3 GHz).

ERS-2, junto con su predecesor ERS-1, fueron los primeros satélites con finalidades comerciales que trabajaron en el espectro electromagnético de las microondas. De polarización simple (VV) y ángulo de incidencia fijo (23°), portaba un sensor radar de apertura sintética (SAR) denominado instrumento activo de microondas (AMI). El programa **ENVISAT/ASAR**, fue la continuación de las misiones ERS-1 y ERS-2 e incorporó una serie de mejoras (Attema et al., 2000). La posibilidad de orientar gradualmente la antena, proporcionó al sensor ASAR (*Advanced Synthetic Aperture Radar*) la posibilidad de trabajar a diferentes ángulos de incidencia (entre 15 y 45°) y en consecuencia a distintos anchos de las franjas (56-105 km). Además, como novedad, disponía de la posibilidad de operar en polarización doble (HH-VV, HH-HV o VV-VH). ENVISAT, estuvo destinado principalmente a la investigación científica (https://earth.esa.int/pub/ESA_DOC/Envisat_ERS_Data_Access_Guide.pdf).

El satélite **ALOS**, fue lanzado en enero del 2006 por la Agencia Espacial Japonesa (JAXA) y estuvo operativo hasta abril del 2011. Portaba tres sensores independientes: PRISM (*Panchromatic Remote-sensing Instrument for Stereo Mapping*), AVNIR-2 (*Advanced Visible and Near Infrared Radiometer-2nd generation*) y PALSAR (*Phased Array type L-band Synthetic Aperture Radar*), pudiéndose adquirir simultáneamente imágenes ópticas y radar con diversas resoluciones y coberturas. El sensor PALSAR trabajaba en la banda-L (1.27 GHz) y era capaz de adquirir datos de hasta 10 m de resolución con ángulos de incidencia entre 20° y 55°. Contaba con cuatro modos de adquisición, cada uno de ellos con una determinada resolución, cobertura y polarización. Las imágenes captadas por PALSAR resultaban muy interesantes en cuanto a resolución, modos de adquisición e incluso desde el punto de vista económico. Sin embargo, presentaban inconvenientes en cuanto a su disponibilidad y dificultades para una programación específica debido a que JAXA, tenía definido un plan de adquisición para, a partir de criterios climáticos, crear un archivo global de imágenes y esta estrategia de adquisición era prioritaria sobre el conjunto de otras peticiones (a excepción de las adquisiciones urgentes que podrían surgir para el seguimiento de grandes catástrofes) (Rosenqvist et al., 2004; 2007). A día de hoy está operativo ALOS-2/PALSAR que, al igual que su predecesor, trabaja en la banda-L. Entre las novedades de este sensor destacan su periodo de revisita (14 días frente a los 46

de ALOS-1), que incorpora el modo de operación Spotlight (resolución de hasta 3 m) y su capacidad de direccionar la antena hacia la derecha e izquierda.

Por último, **RADARSAT-2** fue lanzado con éxito en diciembre del 2007. Se trata de la segunda generación de satélites comerciales canadienses que usan la tecnología SAR (el primero fue RADARSAT-1) en banda-C (5.3 GHz). Entre las características de RADARSAT-2 destacan sus imágenes de alta resolución de hasta un metro, la multipolarización y la flexibilidad en la dirección de observación (la antena puede mirar derecha/izquierda) lo cual posibilita repetir una escena con más frecuencia. Al igual que ENVISAT y ALOS puede trabajar con distintos ángulos de incidencia (20-60°). Sus principales aplicaciones se encuentran en: vigilancia marítima (detección de derrames de hidrocarburos, vigilancia de los hielos para la navegación y detección de buques), geología (exploración minera y petrolera), en la producción de cartografía, en defensa (cartografía y observación), en gestión de riesgos (control de inundaciones), en agricultura y en el ámbito forestal (Morena, 2004).

2.2. Metodologías

Esta sección se divide en varios apartados. En primer lugar se describe el procesamiento de las imágenes y la extracción de los parámetros derivados. A continuación se presentan las distintas herramientas de análisis utilizadas para interpretar los datos y seleccionar los parámetros más importantes y finalmente se describen los algoritmos de clasificación utilizados así como los estadísticos empleados para evaluar la fiabilidad de las clasificaciones obtenidas.

2.2.1. *Procesamiento de las imágenes*

Imágenes ópticas

El procesamiento de las imágenes ópticas consistió en su corrección geométrica y radiométrica. En el primer caso las imágenes se ortorrectificaron utilizando un modelo riguroso de la geometría del sensor implementado en el software ERDAS Imagine y añadiendo puntos de control tomados sobre escenas pancromáticas SPOT ortorrectificadas ya disponibles y un MDT de 5 metros. En todos los casos el error medio cuadrático fue inferior a un píxel. La corrección radiométrica consistió en primer lugar en la transformación de niveles digitales a unidades de radiancia, utilizando para ello los coeficientes disponibles en los metadatos y siguiendo el proceso estándar (Chander et al., 2009). La atmósfera ejerce un efecto perturbador sobre la radiancia que llega al sensor y eso puede limitar seriamente la interpretación de las imágenes y su análisis multitemporal. En este trabajo se corrigió el efecto atmosférico mediante el método semi-empírico iDOS de Chavez (1996), que aun siendo un método sencillo proporciona resultados adecuados (Chuvieco y Hantson, 2010).

Finalmente se transformaron las radiancias corregidas atmosféricamente a valores de reflectividad (Chuvieco y Hantson, 2010), que es la relación existente entre la energía reflejada por una cubierta y la incidente, y varía entre 0 (superficie completamente absorbente) y 1 (superficie completamente reflectora). La reflectividad es una magnitud que se relaciona con características bio-geofísicas de las cubiertas y permite por tanto una mejor interpretación de

las imágenes e incluso el desarrollo de estudios multitemporales o la estimación de variables de interés de las cubiertas.

Imágenes radar

Las imágenes radar utilizadas se adquirieron con diferentes niveles de procesamiento, PRI (o nivel 1.5) y SLC (o nivel 1.1) (Tabla 3). Las primeras presentan el valor de la amplitud para cada píxel codificado en niveles digitales de 16 bits. Además, incorporan un proceso multi-look para reducir el moteado y están proyectadas sobre el terreno. Las imágenes SLC llevan un nivel de procesamiento inferior, no están proyectadas sobre el terreno, se encuentran en geometría *slant range* (plano de proyección normal a la dirección de alcance) y su nivel de ruido es mayor. Las imágenes SLC conservan la información de fase además de la amplitud, por lo tanto son necesarias en aplicaciones en las que se requiere esta información (e.g., polarimetría o interferometría).




Figura 4. Geometría *Slant Range* (a la izquierda) y su correspondiente proyección sobre el terreno o *Ground Range* (a la derecha). La imagen corresponde a la RADARSAT-2 del 5 de junio del 2010, adquirida sobre la zona este de la cuenca de Pamplona.

El procesamiento de las imágenes SLC requirió en primer lugar de la transformación de la geometría *Slant Range* al sistema de proyección sobre el terreno *Ground Range* que incluyó un procesado multi-look. A continuación todas las imágenes se ortorrectificaron utilizando modelos rigurosos de la geometría de los sensores implementados en los software PCI Geomatica o NEST. Para ello se utilizó el MDT de 5 metros mencionado anteriormente y en algún caso se añadieron puntos de control (no siempre fueron necesarios).

Debido a la visión oblicua de los sensores SAR son frecuentes las distorsiones geométricas en zonas de relieve. En estos casos es habitual encontrar zonas que sufren distorsiones como el sombreado, la superposición o la compresión de laderas, lo que hace que al georreferenciar una imagen entera el error observado en la dirección de alcance sea mayor que en la dirección del azimut. Sin embargo en el presente trabajo se estudiaron zonas agrícolas normalmente presentes en valles y zonas relativamente llanas, de modo que estos tipos de distorsiones geométricas fueron prácticamente inexistentes en las zonas investigadas.

Todas las imágenes, tanto las ópticas como las radar, se ortorrectificaron en proyección UTM, sistema de referencia WGS84, Huso 30N, y fueron remuestradas, mediante el método del Vecino más Cercano, a un mismo tamaño de píxel (en cada trabajo concreto). Este tamaño del píxel, de 5 o 10 m, varió en función de la resolución de las imágenes empleadas en cada trabajo.

Al igual que en el caso de las imágenes ópticas, las imágenes radar requieren de una calibración para transformar los niveles digitales originales a magnitudes físicas que se puedan interpretar en términos de características bio-geofísicas del terreno. Mediante esta calibración, realizada a partir de las constantes de calibración proporcionadas en los metadatos de las imágenes y tras compensar las variaciones del ángulo de incidencia local dentro de cada imagen (Ulander, 1996), se obtuvo para cada píxel el valor del coeficiente de retrodispersión (σ° o *backscattering coefficient*) en las polarizaciones disponibles.

El valor de σ° , representa el ratio entre la potencia total recibida por el sensor y la emitida inicialmente hacia un píxel. Como ya se ha mencionado en la introducción, σ° varía en función de la frecuencia (banda) del sensor, de su ángulo de incidencia y polarización (HH, HV, VH, VV). Los valores de σ° observados se pueden interpretar en función de tres principales mecanismos de retrodispersión: (i) superficial, (ii) doble rebote y (iii) de volumen, Figura 5.




Figura 5. Principales mecanismos de dispersión.

Estos mecanismos están relacionados con las características de las distintas cubiertas del terreno (agua, zonas urbanas, bosques, campos agrícolas e incluso distintos cultivos, etc.). En términos generales, las superficies de aguas en calma o superficies muy lisas como por ejemplo carreteras, pistas de aterrizaje, etc., se comportan de forma especular, de modo que la señal no retorna a la antena (estos píxeles se ven muy oscuros en una imagen radar). Elementos como postes eléctricos, edificios o estructuras (objetos verticales en general), actúan como reflectores discretos cuyo principal mecanismo es la doble reflexión o de esquina. En estos casos la señal que retorna a la antena es muy intensa por lo que aparecen como zonas muy brillantes (casi saturadas sobre la imagen radar). En zonas forestales, cultivos densos, superficies muy rugosas, etc., el principal mecanismo es la retrodispersión de volumen. En estos casos retorna solamente una parte de la señal que se emite (en función de características geométricas y dieléctricas de las cubiertas) y estas zonas se suelen ver con tonalidades grises en las imágenes radar. En función de la polarización empleada se favorece la

sensibilidad a un mecanismo de retrodispersión u otro. En general, en fenómenos de reflexión superficial y de doble rebote el pulso dispersado mantiene la misma polarización que tenía el pulso incidente (detectable en polarizaciones directas), mientras que en fenómenos de reflexión múltiple se producen cambios en la polarización (detectables en polarizaciones cruzadas).

Además de los coeficientes de retrodispersión en las polarizaciones disponibles (σ_{HH}° , σ_{HV}° , σ_{VH}° y/o σ_{VV}°), en observaciones con polarización doble o cuádruple se calcularon también sus ratios (ratio de polarización directa $\sigma_{HH}^{\circ}/\sigma_{VV}^{\circ}$ y los ratios de polarización cruzada $\sigma_{HV}^{\circ}/\sigma_{HH}^{\circ}$ y $\sigma_{VH}^{\circ}/\sigma_{VV}^{\circ}$). Por último, en los casos en los que se partió de observaciones polarimétricas se calcularon una serie de parámetros polarimétricos partiendo inicialmente de la matriz de dispersión. Esta matriz, describe la transformación de una onda incidente (superíndice i) en una onda retrodispersada (superíndice s) y representa las características dispersoras de la cubierta observada,

$$\begin{bmatrix} E_H^s \\ E_V^s \end{bmatrix} = \begin{bmatrix} S_{HH} & S_{HV} \\ S_{VH} & S_{VV} \end{bmatrix} \cdot \begin{bmatrix} E_H^i \\ E_V^i \end{bmatrix} \quad (1)$$

Los cuatro elementos de la matriz de retrodispersión son complejos y se determinan a partir de la medición de la amplitud y la fase en las cuatro polarizaciones. A continuación, se detallan los parámetros polarimétricos calculados:

- **Potencia total (Span):** representa la potencia total recibida por los cuatro canales de un sensor radar polarimétrico.

$$P_T = |S_{HH}|^2 + |S_{HV}|^2 + |S_{VH}|^2 + |S_{VV}|^2 \quad (2)$$

- **Coherencia o coeficiente de correlación de polarización directa:** representa la correlación entre los dos canales de polarización directa. Es una magnitud compleja que se calcula como el producto entre la amplitud compleja en el canal HH y su conjugado en el canal VV. Se normaliza mediante la raíz cuadrada del producto de las potencias en los canales HH y VV. Este parámetro puede emplearse para detectar depolarización. Cuando la dispersión de superficie es predominante su valor se acerca a 1 mientras que en cubiertas donde la dispersión de volumen predomina su valor es cercano a 0.

$$\rho_{HH/VV} = \frac{\langle S_{HH} S_{VV}^* \rangle}{\sqrt{(|S_{HH}|^2)(|S_{VV}|^2)}} \quad (3)$$

- **Diferencia de fase de polarización directa (ϕ_{HHVV}):** es el valor de la diferencia de fase entre los dos canales co-polarizados y da idea del número de reflexiones o rebotes que sufre la onda. Un valor de 0° corresponde a una única reflexión (o un número impar) y representa la dispersión superficial, mientras que un valor de 180° corresponde a rebotes dobles (o pares) que ocurren con reflectores de esquina. Las cubiertas vegetales no suelen presentar un valor de ϕ_{HHVV} definido.

- **Descomposición de Pauli:** consiste en descomponer la matriz de dispersión en tres componentes que se relacionan con el mecanismo de dispersión superficial ($|S_{HH} + S_{VV}|^2$), con la dispersión de volumen ($|S_{HV} + S_{VH}|^2$) y con el doble rebote ($|S_{HH} - S_{VV}|^2$), respectivamente. Dichos parámetros permiten visualizar e interpretar de forma más intuitiva los mecanismos de retrodispersión predominantes en una imagen.
- **Descomposición de Cloude y Pottier (1996) H/A/ α :** Entropía (H), Anisotropía (A) y Ángulo alfa (α). Estos parámetros resumen la información polarimétrica y la descomponen en términos de los mecanismos de retrodispersión que se producen en las cubiertas, lo que está directamente relacionado con su naturaleza.
La entropía H representa el grado de aleatoriedad o desorden estadístico en los mecanismos de retrodispersión. Varía entre 0, un único mecanismo dominante y 1, mezcla aleatoria de mecanismos de retrodispersión. El ángulo alfa proporciona un valor relativo al mecanismo de retrodispersión, oscila entre 0°, dispersión superficial y 90°, reflexión de esquina, con valores intermedios de 45° ilustrando la dispersión de volumen. Se puede calcular el valor de alfa medio (α), lo que representa el mecanismo promedio en una cubierta o el alfa dominante (α_1), que permite identificar el mecanismo principal. Por último, la anisotropía A se interpreta en términos de la homogeneidad de la cubierta, dado que mide la importancia relativa de los mecanismos de retrodispersión minoritarios (secundario y terciario). Cubiertas homogéneas tienen valores bajos de A, mientras que cubiertas heterogéneas toman valores altos.
- **Coefficientes y ratios de polarización en otras bases:** Como se ha comentado, los sensores polarimétricos usan un par de canales de polarización ortogonales (típicamente H y V) en los que miden la amplitud y fase de la señal retrodispersada, información que se representa mediante la matriz de dispersión. Conocida esta matriz, es posible calcular la respuesta de las cubiertas en cualquier otra combinación ortogonal de polarizaciones, mediante el procedimiento conocido como síntesis de polarización. En este trabajo se consideraron otras dos bases de polarización: la circular (polarizaciones LL, LR, RL y RR) y la lineal 45° (polarizaciones +45°+45°, +45°-45°, -45°+45° y -45°-45°), por lo que se calcularon sus correspondientes coeficientes de retrodispersión y sus ratios de polarización directa y cruzada.

El moteado o *speckle*, es una distorsión radiométrica inherente a cualquier sistema de adquisición de imágenes radar y hace que las imágenes tengan una apariencia granulosa. La presencia del moteado causa una reducción en la calidad de las imágenes debido a que se disminuye su interpretabilidad y su capacidad de detectar objetos o identificar cubiertas. Existen básicamente dos técnicas para reducir el moteado: el ya comentado procesado multi-look y el filtrado de las imágenes. Se han usado filtros de distinto tipo como filtros de paso bajo, filtros adaptativos, filtros polarimétricos o filtros multitemporales. Los dos últimos son aplicables únicamente cuando se cuenta con observaciones polarimétricas y cuando se cuenta con una serie multitemporal de imágenes, respectivamente.

En el presente trabajo se utilizaron los filtros adaptativos de Lee y Gamma MAP con una ventana de 3x3. Ambos filtros resultaron efectivos para reducir el moteado sin suprimir elementos lineales presentes en las imágenes (Lopes et al., 1993). Las imágenes filtradas presentaron una menor granulosidad y un aspecto más homogéneo, aunque a costa de la reducción de su resolución espacial, Figura 6.




Figura 6. Las escenas que se muestran corresponden a la combinación de las bandas HH-HV-VV (RGB) de RADARSAT-2 del 5 de junio sin filtrar (izquierda) y filtrado (derecha). La zona que se muestra corresponde a la ciudad de Pamplona y a algunas de las parcelas agrícolas que le rodean.

El procesamiento de las imágenes radar se llevó a cabo con distintas versiones de los softwares comerciales PCI Geomatics y ERDAS Imagine, y también con distintas versiones de los softwares libres PolSARpro y NEST (actualmente denominado Sentinel-1A Toolbox).

Por último, una vez procesadas las imágenes ópticas y/o radar, se corregistraron para garantizar un ajuste preciso entre observaciones de distintas fuentes y se calcularon los estadísticos de todos los parámetros (coeficientes de retrodispersión y parámetros polarimétricos) objeto de estudio, por parcela. A estas parcelas se les aplicó un buffer de 1 píxel para excluir los bordes de las parcelas. Estos valores fueron los que se emplearon en el análisis de los datos y en las clasificaciones. Por tanto, el nivel o escala de estudio en todos los trabajos de esta tesis es la parcela agrícola, por lo que se puede decir que se ha trabajado a nivel de objeto, en contraposición con el trabajo a nivel de píxel, frecuente en otro tipo de aplicaciones. Esta decisión se tomó debido a que los cultivos agrícolas se manejan a nivel de parcela, siendo muy improbable el caso de una parcela que presente simultáneamente dos o más cultivos. Al trabajar a nivel de parcela se reduce la variabilidad de las observaciones a nivel de píxel y se consiguen unas clasificaciones más robustas.

2.2.2. Análisis de los datos

De forma previa a la realización de clasificaciones y con el fin de seleccionar los coeficientes de retrodispersión y parámetros más significativos, se analizó la firma o respuesta de las áreas de entrenamiento (*training sets*) correspondientes a los diferentes cultivos. Para ello se

seleccionaron varias áreas por categoría, a fin de asegurar su representatividad y reflejar adecuadamente su variabilidad en la zona de estudio. Se realizó una comparativa entre los valores de los parámetros estudiados entre los diferentes cultivos y en un mismo cultivo a lo largo del tiempo. Se trató de interpretar las observaciones en términos de la morfología, configuración y características de las diferentes cubiertas.

Además de ese análisis gráfico previo, se realizó también un análisis numérico de separabilidad. Este segundo análisis, consistió en evaluar la disimilitud estadística (o separabilidad) entre los cultivos objeto de estudio, para los diferentes parámetros y fechas. Si bien al principio se utilizó la distancia normalizada (D_N) (Swain y Davis, 1978),

$$D_N(A, B) = \frac{|\bar{\mu}_A - \bar{\mu}_B|}{\sigma_A + \sigma_B} \quad (4)$$

donde $\bar{\mu}$ y σ representan la media y la desviación estándar de cada cultivo (A y B) respectivamente, posteriormente, se optó por utilizar la distancia de Jeffries-Matusita (D_{JM}) (Swain, 1973), debido principalmente a que es un indicador que no supone a priori normalidad en los datos a comparar y tiene un rango de valores acotado. La ecuación que representa la distancia de JM es,

$$D_{JM} = \left\{ \int_x [\sqrt{f(x)} - \sqrt{g(x)}]^2 dx \right\}^{1/2} \quad (5)$$

donde x se refiere a la variable estudiada (por ejemplo el coeficiente de retrodispersión de una determinada polarización, o el ratio, etc.) y $f(x)$ y $g(x)$ son las funciones de probabilidad de un par de cultivos o categorías diferentes.

El valor de D_{JM} varía de 0 a 2, donde 0 representa dos categorías que se solapan completamente, valores inferiores a 1 representan baja separabilidad, valores entre 1-1.5 corresponden a separabilidad media, valores superiores a 1.5 a alta separabilidad y valores de 2 a una separabilidad completa entre las dos categorías (Skriver, 2007). La distancia D_{JM} se ha utilizado con frecuencia para procesos de análisis de similitud y de selección de variables (*feature selection*). En el campo de la teledetección SAR hay una serie de estudios previos que usan y recomiendan el uso de D_{JM} (e.g., Michelson, 2000; Skriver, 2007).

2.2.3. Algoritmos de clasificación

Partiendo tanto de observaciones radar como de ópticas es posible realizar clasificaciones tanto supervisadas como no supervisadas. En el caso de las clasificaciones supervisadas, se definen unas áreas de entrenamiento que representan zonas del terreno donde se conoce las clases que hay presentes. En las clasificaciones tradicionales, se calculan las estadísticas de cada clase y posteriormente se asignan los píxeles u objetos (según se esté clasificando a nivel de píxel u objeto) de la imagen a las diferentes clases siguiendo criterios de probabilidad como la distancia mínima o la máxima verosimilitud.

Al contrario, las clasificaciones no supervisadas se realizan sin tener en cuenta zonas de entrenamiento o verdad campo. El principal problema de estas clasificaciones reside en la interpretación de las clases obtenidas que se ha de realizar a posteriori.

En todos los trabajos presentados se realizaron clasificaciones supervisadas debido principalmente a que se contaba con información de verdad campo. Se considera el ámbito de estudio de las clasificaciones no supervisadas lo suficientemente amplio como para justificar un análisis específico, que por su magnitud queda fuera del alcance de esta tesis.

En cuanto al nivel de clasificación (por píxel o por objeto), se optó por trabajar a nivel de objeto. Para ello, se utilizaron las parcelas agrícolas obtenidas del SIGPAC correspondiente a la zona y al año de estudio. Posteriormente, se asignó a cada una de las parcelas el valor de la mediana de sus píxeles en cada uno de los parámetros estudiados (coeficientes de retrodispersión, sus ratios y los parámetros polarimétricos estudiados). Varios autores (Dong et al., 2001; Quegan, 2003; Alberga, 2007) observaron mejores resultados en clasificaciones a nivel de parcela que a nivel de píxel.

Se utilizaron distintos algoritmos de clasificación. En los primeros trabajos se utilizaron algoritmos de clasificación convencionales:

- **Clasificador de máxima verosimilitud (MLC)**, donde se considera que los valores de cada clase se ajustan a una distribución normal en todos los parámetros o variables predictivas que intervienen en la clasificación. A partir de la media y de la varianza se calcula la probabilidad de pertenencia del píxel u objeto a clasificar a cada una de estas clases. Cada píxel u objeto se asigna a aquella clase que consiga maximizar esta probabilidad. En los casos en los que se utilizan varios parámetros lo que se calcula es el vector de medias y la matriz de covarianza. Este clasificador se ha utilizado y utiliza con asiduidad para la clasificación de imágenes ópticas multiespectrales. Además, el clasificador MLC permite introducir un factor opcional en el criterio de decisión, la probabilidad a priori de cada clase, que permite contemplar diferencias entre clases más o menos probables. Esta probabilidad a priori se multiplica por la probabilidad de pertenencia, lo que tiene un efecto determinante en el resultado de la clasificación favoreciendo la asignación de píxeles u objetos a las clases más frecuentes. Aun siendo una alternativa interesante, resulta complejo establecer un criterio adecuado para estimar los valores de probabilidad a priori de cada clase. Un posible criterio es el de conceder a cada categoría una probabilidad a priori equivalente a la superficie que ocupa en la zona de estudio, estimada mediante un inventario previo. En los trabajos de esta tesis en los que se utilizó este clasificador (Larrañaga et al., 2010; 2011a; 2011b) se contó con un inventario de este tipo, facilitado por la Sección de Evaluación de Recursos Agrarios del Gobierno de Navarra.
- **Clasificador de Mahalanobis**. Este algoritmo también asume una distribución de probabilidad normal en los datos de entrada. Cada píxel u objeto se asigna a la clase para la que la distancia de Mahalanobis es mínima. Dicha distancia es similar a la distancia Euclídea pero en su cálculo se tiene en cuenta también la matriz de covarianza. Por tanto, este clasificador suele dar mejores resultados cuando: (i) los

parámetros que se utilizan están correlacionados y/o (ii) las clases tienen un rango de variación muy heterogéneo.

En esta tesis, el clasificador de Mahalanobis se utilizó en casos donde se combinaban imágenes ópticas y radar. En estos casos se comprobó que funcionaba mejor que MLC debido a la heterogeneidad de algunas clases.

Más adelante, se constató que varios autores (Bruzzone et al., 2004; Del Frate et al., 2003; McNairn et al., 2009; Waske y Braun, 2009), coincidían en que cuando se trabajaba con imágenes radar, había que evitar los algoritmos de clasificación diseñados para los datos con distribuciones normales (MLC, Mahalanobis) puesto que los datos de partida (coeficientes de retrodispersión, ratios o parámetros polarimétricos) no se ajustan necesariamente a esa distribución. Por este motivo se optó por utilizar el algoritmo de clasificación *Random Forests* (RF), (Breiman, 2001).

- **Clasificador *Random Forest* (RF)** (Breiman, 2001), es un clasificador múltiple basado en técnicas de inteligencia artificial que consiste en la construcción automática de múltiples árboles de decisión (k) que clasifican individualmente cada píxel u objeto y donde la clase final se asigna por mayoría. Cada árbol se construye a partir de un conjunto de datos (*training sets*) distinto, seleccionados aleatoriamente y con reemplazo. Los nodos de cada árbol se dividen utilizando la mejor variable de división (aquella que maximice un estadístico de desigualdad denominado índice de Gini) entre un subconjunto (m) de variables predictivas seleccionados al azar. Siendo las variables y reglas de división de los nodos diferentes en cada árbol se asegura su heterogeneidad, por lo que cada uno obtendrá un resultado diferente. La asignación final por mayoría permite compensar los errores individuales de cada árbol y llegar a una solución óptima.

Dentro del conjunto de datos de partida, el clasificador guarda $1/3$ para calcular el error *out of bag* (OOB). Este error OOB se estima de forma interna y objetiva y sirve para optimizar los parámetros (m y k) del clasificador y evaluar la fiabilidad de la clasificación obtenida (Figura 7). Opcionalmente, se puede evaluar la fiabilidad de la clasificación utilizando otro conjunto de datos externo (*test set*), para garantizar la independencia de la validación.

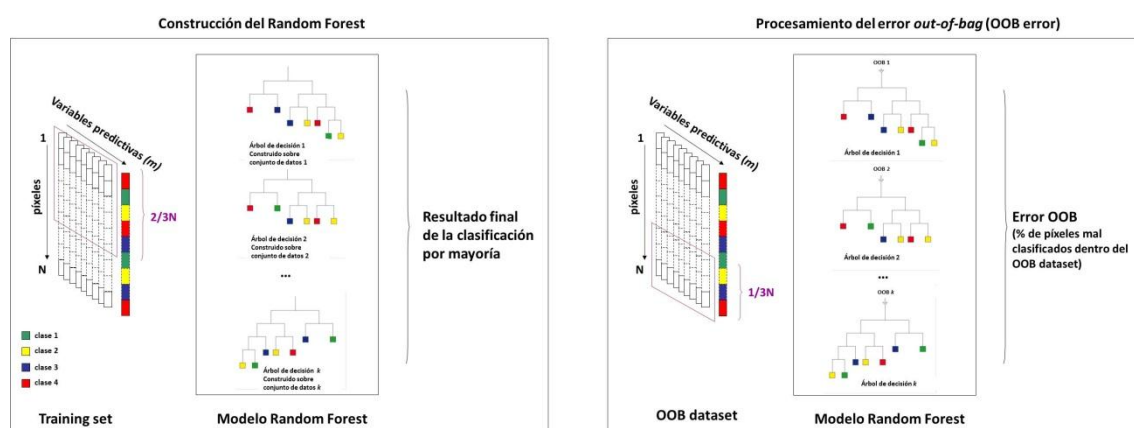


Figura 7. Esquema general del clasificador *Random Forest*.

El número de árboles (k) y el número de variables predictivas (m) utilizados para dividir los nodos los define el usuario. Éstos se calibran u optimizan con el fin de minimizar el error OOB. La técnica RF se ha aplicado a una amplia variedad de disciplinas y, en los últimos años, se ha utilizado con éxito en aplicaciones de teledetección (Waske y van der Linden, 2008; Waske y Braun, 2009; Belgiu y Drăguț, 2016).

Las principales ventajas de esta técnica radican en que el algoritmo funciona adecuadamente en condiciones de alta dimensionalidad (número elevado de variables predictivas), que es capaz de incorporar variables correlacionadas sin que esto afecte a su estabilidad y que produce resultados adecuados incluso cuando el tamaño de la muestra es reducido. Además, es eficiente y el tiempo de computación que necesita es corto. Por último puede incorporar variables predictivas de diferente tipo (numéricas, categóricas, etc.) y no asume ningún tipo de distribución de probabilidad en las mismas.

En los últimos dos trabajos (Larrañaga et al., 2013; Larrañaga y Álvarez-Mozos, 2016) se trabajó con este clasificador, obteniendo unos resultados muy satisfactorios.

2.2.4. Evaluación de la fiabilidad de las clasificaciones

La fiabilidad de una clasificación representa el grado de coincidencia entre las clases asignadas por el clasificador y las obtenidas mediante trabajo de campo (verdad campo) en una muestra (*test set*) considerada representativa e independiente a la utilizada para entrenar el clasificador (Tso, 2009). La herramienta más empleada para evaluar dicha fiabilidad es la matriz de confusión, de la que se pueden calcular distintos estadísticos de fiabilidad. La matriz de confusión consiste en la representación en filas y columnas de las clases asignadas respecto a las clases observadas para los distintos elementos del *test set*. En este trabajo se construyeron las matrices de las distintas clasificaciones obtenidas y se calcularon los siguientes estadísticos de fiabilidad:

Tabla 4. Ejemplo de matriz de confusión.

		Verdad campo (j)			
		Clase ₁	Clase ₂	...	Clase _n
Clasif. (i)	Clase ₁	X ₁₁	X ₁₂	...	X _{1n}
	Clase ₂	X ₂₁	X ₂₂	...	X _{2n}

	Clase _n	X _{n1}	X _{n2}	...	X _{nn}

- La **Fiabilidad o precisión global (FG)**, es el estadístico más simple que se deriva de la matriz de confusión y se obtiene dividiendo el número total de los objetos correctamente clasificados (suma de la diagonal de la matriz) por el total de los objetos clasificados (Tso, 2009).

$$FG = \frac{\sum_{i,j=1}^n X_{i=j}}{\sum_{i,j=1}^n X_{i,j}} \quad (6)$$

donde, X_{ij} indica el número de objetos en la fila i (clase asignada por el clasificador) y columna j (clase observada en campo) de la matriz de confusión y $X_{i=j}$ representa

valores de la diagonal de la matriz de confusión, es decir, los objetos correctamente clasificados. Pese a su uso generalizado y facilidad de interpretación, este indicador tiene inconvenientes como que considere todos los errores por igual, sin valorar independientemente cada clase o que suele sobrestimar la bondad de la clasificación al no considerar los casos que hayan podido ser correctamente clasificados por azar.

- La **Fiabilidad del usuario (Fu)**, se calcula para cada clase independientemente y refleja la probabilidad de que los píxeles asignados a una determinada clase, representen realmente dicha clase en el terreno.

$$Fu_i = \frac{X_{i=j}}{\sum_{j=1}^n X_{i,j}} \quad (7)$$

donde, $X_{i=j}$ representa los valores de la diagonal de la matriz de confusión (elementos correctamente clasificados) y X_{ij} los objetos en una determinada fila i (clase asignada por el clasificador), i indica la fila y j la columna.

- La **Fiabilidad del productor (Fp)**, se calcula para cada clase independientemente e indica la proporción de la verdad campo que se clasifica correctamente.

$$Fp_j = \frac{X_{i=j}}{\sum_{i=1}^n X_{i,j}} \quad (8)$$

donde, $X_{i=j}$ representa los valores de la diagonal de la matriz de confusión (elementos correctamente clasificados) y X_{ij} los objetos en una determinada columna j (clase observada en campo), i indica la fila y j la columna.

Los estadísticos Fu y Fp , son complementarios y deben analizarse conjuntamente para cada clase.

- El **índice de Hellden** (Hellden, 1980), se calcula para cada clase y refleja la fiabilidad del usuario y del productor conjuntamente, ya que es la media armónica de ambas medidas y, por tanto, relaciona los píxeles bien clasificados para una determinada clase con los marginales en filas y columnas de la matriz de confusión.
- **Kappa**, es un coeficiente muy utilizado como indicador de calidad global de la clasificación. Es más estricto que la fiabilidad global dado que utiliza los elementos marginales de la matriz de confusión para determinar los elementos adecuadamente clasificados por el azar y los extrae de la evaluación (Cohen, 1960). Por tanto, su valor da idea del porcentaje de acuerdo obtenido en la clasificación una vez eliminada la parte que se debería al azar.

$$k = \frac{P_o - P_e}{1 - P_e} \quad (9)$$

donde, P_o representa la proporción de acuerdo observado (FG) y P_e representa la proporción de acuerdo esperado por azar.

La Tabla 5, muestra la calidad de la clasificación en función del estadístico Kappa según Landis y Koch, 1977.

Tabla 5. Categorización de los valores de Kappa según Landis y Koch (1977).

Kappa	Calidad
< 0.00	Mala
0.00 – 0.20	Pobre
0.21 – 0.40	Razonable
0.41 – 0.60	Buena
0.61 – 0.80	Muy buena
0.81 – 1.00	Excelente

Para una mejor interpretación de los resultados, muchos de los resultados obtenidos se presentaron mediante gráficas.

3. Presentación de los trabajos

La tesis contiene cinco aportaciones (un informe y cuatro artículos) relacionadas con la clasificación de cultivos a partir de observaciones de teledetección radar. Cada una de estas aportaciones aborda un objetivo específico distinto. A continuación se presenta una breve descripción de cada una de ellas y al final de esta sección se incluyen los trabajos completos.

1) Clasificación de cultivos en la zona media de Navarra mediante imágenes radar polarimétricas (Larrañaga et al., 2010).

Este trabajo se presentó en una versión preliminar en el XIII Congreso de la Asociación Española de Teledetección, celebrado en Calatayud entre el 23 y 26 de septiembre de 2009, y posteriormente en una versión ampliada y revisada en el número 34 de la Revista de Teledetección en 2010.

Los primeros sensores radar (ERS-1/-2, RADARSAT-1 y JERS) trabajaban en una única polarización (generalmente directa, HH o VV) por lo que las imágenes adquiridas contaban con un solo canal de información. Si bien este tipo de imágenes se utilizaron en varios trabajos de clasificación de cultivos (e.g., Waske y van der Linden, 2008), se observó en general que el uso de una única imagen de estas características resultaba claramente insuficiente para clasificar cultivos (Lee et al., 2001). Los sensores que les siguieron a estos primeros (ALOS-1, -2/PALSAR, RADARSAT-2, etc.), incorporaron, entre otras mejoras, la capacidad de adquirir información en múltiples polarizaciones. Al adquirir imágenes en varias polarizaciones se añadían canales con información adicional interesante lo cual resultó de utilidad para interpretar y clasificar el terreno.

El objetivo de este trabajo consistió en evaluar la viabilidad de las observaciones radar de polarización múltiple en la clasificación de cultivos tanto de secano como de regadío. Se utilizaron dos imágenes ALOS-1/PALSAR polarimétricas, adquiridas el 25 de marzo y 10 de mayo del 2007. El área de estudio correspondió a la zona oeste de Navarra (Zona de estudio 1, Figura 1) abarcando las localidades de Estella, Cirauqui, Puente la Reina, Larraga, Mendigorriá, Miranda de Arga y Lerín entre otras. Todos los cultivos estudiados: cereales (trigo, cebada y avena), alfalfa, habas, girasol, colza, espárrago, guisante, pradera y barbecho, a excepción de la

colza, se encontraron tanto en zonas de secano como de regadío, aunque la superficie total de regadío fue muy inferior a la de secano (3,147 ha de regadío frente a las 53,989 ha de secano). Las zonas de regadío se situaban principalmente en las localidades de Miranda de Arga y Lerín.

Además de los coeficientes de retrodispersión de cada polarización (σ_{HH}° , σ_{HV}° , σ_{VH}° , σ_{VV}°), se calcularon distintos parámetros polarimétricos (P_T , $\sigma_{HV}^{\circ}/\sigma_{VV}^{\circ}$, $\sigma_{RR}^{\circ}/\sigma_{RL}^{\circ}$, $|\rho_{HHVV}|$, Φ_{HHVV} , H , A y α). Posteriormente, en base al estudio de la matriz de correlación, análisis de firmas y la separabilidad entre cultivos según Lee et al. (2001), se seleccionaron los parámetros más significativos, que fueron σ_{HH}° , σ_{HV}° , α , $|\rho_{HHVV}|$, $\sigma_{HV}^{\circ}/\sigma_{VV}^{\circ}$ y $\sigma_{RR}^{\circ}/\sigma_{RL}^{\circ}$.

La clasificación se realizó de forma supervisada y a nivel de parcela en base al SIGPAC de la zona de estudio. Como verdad campo se utilizó la información de las inspecciones de las declaraciones de la PAC de aquel año. Los cereales (trigo, cebada y avena) se unieron en una única clase debido a que en la época en la que se adquirieron las imágenes, presentaban un desarrollo vegetativo prácticamente idéntico y se confundían mucho. El algoritmo de clasificación que se utilizó en esta ocasión fue el de máxima verosimilitud (MLC) y en el esquema de clasificación se incorporaron únicamente los parámetros previamente seleccionados (identificados como los más significativos).

Los resultados demostraron que las fechas de adquisición de las imágenes de partida (primavera) no fueron las adecuadas, más aun teniendo en cuenta la gran proporción de cultivos de verano en la zona de estudio. Debido a la estrategia de adquisición de JAXA, para esta zona de estudio no se contó con más imágenes por lo que se trabajó con las disponibles. Aun así, los resultados obtenidos fueron relativamente satisfactorios (FG de 85% y Kappa de 0.52) y similares a los obtenidos en estudios de este tipo basados en imágenes radar (Rodrigues et al., 2003). Pese a las limitaciones que se encontraron en cuanto a las imágenes disponibles, este trabajo demostró que era viable el uso de las imágenes radar polarimétricas para la clasificación de cultivos.

2) Crop classification in rain-fed and irrigated agricultural areas using Landsat-TM and ALOS/PALSAR data (Larrañaga et al., 2011a).

Este trabajo se publicó en el volumen 37 de la revista *Canadian Journal of Remote Sensing* en octubre de 2011.

En los años 1980 y 1990 los sistemas de teledetección óptica multiespectral fueron la base para la identificación y seguimiento de cultivos mediante estrategias de clasificación supervisada, viéndose que la precisión de dichas clasificaciones dependía del número y de la fecha en la que se adquirían las imágenes (Lillesand, 2000). En este sentido es importante utilizar imágenes adquiridas cuando las diferencias entre los cultivos son más aparentes (e.g., Larrañaga et al., 2010). Este problema está estrechamente relacionado con la limitación del uso de sensores ópticos en condiciones de nubosidad. La cubierta nubosa puede limitar e incluso imposibilitar el uso de imágenes ópticas de teledetección y esta limitación, es difícil de superar en el caso de la clasificación de cultivos, a menos que se utilicen fuentes de datos alternativos. Los sensores de teledetección radar proporcionan una alternativa interesante (Skriver, 2012). Estos sensores son activos y trabajan en el espectro de las microondas, por lo que pueden adquirir datos independientemente de la nubosidad e incluso en ausencia de la

luz solar (pueden trabajar de noche y de día). Además aportan información complementaria a la capturada por los sensores ópticos.

En el trabajo anterior (Larrañaga et al., 2010) se vio que las fechas de adquisición de las imágenes ALOS-1/PALSAR utilizadas (marzo y mayo) no eran las idóneas para clasificar los cultivos presentes en la zona de estudio. Partiendo de esa base y contando con una imagen óptica multiespectral de finales de verano, el objetivo de este trabajo consistió en evaluar si la combinación de dichas imágenes mejoraba el resultado final de clasificación de cultivos. Para ello se contó con una imagen Landsat 5-TM, adquirida el 11 de agosto de 2007 y las dos imágenes ALOS-1/PALSAR polarimétricas, previamente utilizadas, adquiridas el 25 de marzo y el 10 de mayo de 2007. Hay que indicar que ninguna de las tres imágenes fue adquirida en las fechas a priori idóneas para clasificar los cultivos presentes en la zona, sin embargo esta era una situación que se podía producir en un caso de aplicación real, de ahí su interés.

El área de estudio fue la misma que la utilizada en Larrañaga et al. (2010), la denominada zona de estudio 1 (Figura 1). Los cultivos estudiados fueron también los mismos (trigo, cebada, avena, alfalfa, habas, girasol, colza, espárrago, guisante, pradera y barbecho) con la diferencia que en esta ocasión los cereales se clasificaron individualmente.

Se realizaron clasificaciones supervisadas a nivel de parcela utilizando distintas combinaciones de imágenes: (i) Landsat 5-TM solo, (ii) ALOS-1/PALSAR solo (marzo y mayo), (iii) Landsat 5-TM + ALOS-1/PALSAR (marzo), (iv) Landsat 5-TM + ALOS-1/PALSAR (mayo) y (v) Landsat 5-TM + ALOS-1/PALSAR (marzo y mayo). Se consultaron diferentes estudios que combinaban imágenes ópticas y radar para clasificar cultivos y se observó que muchos de ellos utilizaban el clasificador de máxima verosimilitud (MLC) obteniendo buenos resultados (e.g., Michelson, 2000; Ban, 2003; McNairn et al., 2009). En base a estos estudios consultados, el algoritmo de clasificación que se utilizó fue el de máxima verosimilitud. Los parámetros polarimétricos utilizados en la clasificación (σ°_{HH} , σ°_{HV} , α , $|\rho_{HHVV}|$, $\sigma^{\circ}_{HV}/\sigma^{\circ}_{VV}$ y $\sigma^{\circ}_{RR}/\sigma^{\circ}_{RL}$), se seleccionaron en base a estudios previos (Larrañaga et al., 2010) y recomendaciones de la bibliografía (Quegan, 2003).

Los resultados demostraron que el uso combinado de imágenes radar polarimétricas y ópticas, mejoraba los resultados obtenidos individualmente con cada tipo de observación. En este último caso la imagen Landsat 5-TM alcanzó una FG e índice de Kappa de 58% y 0.24, y las dos imágenes ALOS-1/PALSAR por su parte obtuvieron una FG e índice de Kappa de 47% y 0.17. Estos resultados son peores que los obtenidos en Larrañaga et al. (2010), debido al hecho de clasificar los cereales de forma individual. La combinación óptico-radar mejoró estos valores, llegando a una FG y Kappa de 60% y 0.33. Estos resultados mejoraron significativamente cuando se agruparon los cereales (trigo, cebada y avena) en una única clase. En ese caso, los mejores resultados se obtuvieron al combinar Landsat 5-TM con las dos imágenes ALOS-1/PALSAR (FG de 90% y Kappa de 0.67). Con todo, la mejora observada al incorporar las dos imágenes radar a la imagen óptica no fue muy significativa. Teniendo en cuenta el tipo de cultivos de la zona de estudio (de porte medio o bajo), se cree que las bandas-C y/o -X podrían incorporar información más útil que la que aporta la banda-L. Esta banda-L posee una capacidad de penetración mayor de modo que el coeficiente de retrodispersión está probablemente más influenciado por el suelo que por el cultivo en sí, sobre todo en las fechas

de adquisición utilizadas en este trabajo. Imágenes adquiridas en junio podrían probablemente ofrecer resultados mejores.

3) Evaluación de la viabilidad del empleo de imágenes radar multitemporales de configuración simple y de la combinación radar-óptico para la clasificación de los cultivos de secano (Larrañaga et al., 2011b).

Este trabajo se redactó a modo de informe técnico elaborado a solicitud de la Sección de Evaluación de Recursos Agrarios del Departamento de Desarrollo Rural, Agricultura y Administración Local del Gobierno de Navarra, durante el contrato Torres Quevedo de la doctoranda en Tracasa.

Tal y como se ha comentado anteriormente, la disponibilidad de imágenes ópticas multiespectrales para la clasificación de cultivos se ve comprometida en varias zonas del globo debido a las persistentes condiciones de nubosidad. En el caso concreto de Navarra lo ideal resulta disponer de una imagen de mediados de la primavera, otra de comienzos del verano y una tercera de finales del verano. Sin embargo, la primavera y el comienzo del verano suelen ser fechas con frecuente nubosidad y en ocasiones únicamente se dispone de una imagen adquirida a finales del verano. El principal objetivo de este trabajo consistió en evaluar la mejora de la fiabilidad de las clasificaciones al combinar una única imagen óptica con varias escenas radar, que aun siendo de configuración simple, abarcaran los meses de mayor interés con vistas a clasificar los cultivos. Para ello se consideró el año agrícola 2008/2009. Se emplearon tres imágenes Landsat 5-TM adquiridas entre mayo y julio del 2009, cuatro imágenes ERS-2, adquiridas entre abril y finales de julio del 2009 y una imagen ENVISAT de junio del 2009. Las imágenes cubrieron la mayor parte de la cuenca de Pamplona (Navarra), la denominada zona de estudio 2 (Figura 1). En esta zona los cultivos de regadío eran prácticamente inexistentes por lo que se consideraron únicamente los cultivos de secano. Los cultivos que formaron parte de las clasificaciones fueron: trigo, cebada, avena, girasol, guisante, habas, colza y pastos. Como información auxiliar se utilizó el SIGPAC del año de estudio y la información de las inspecciones de las declaraciones de la PAC (verdad campo).

Las clasificaciones se realizaron de forma supervisada y a nivel de parcela. En función del tipo de los datos (óptico, radar o la combinación de ambos) y en base a análisis preliminares realizados, se utilizó el algoritmo de clasificación de máxima verosimilitud (MLC) (imágenes ópticas) o el de Mahalanobis (imágenes radar y combinaciones óptico-radar).

Las tres imágenes ópticas se clasificaron primeramente de forma individual, siendo las escenas de mayo y junio las más interesantes, alcanzando una fiabilidad global de 76% y 80% y un índice de Kappa de 0.64 y 0.70 respectivamente. La imagen de julio produjo un peor resultado debido esencialmente a que en esas fechas de adquisición todos los cultivos excepto el girasol se encontraban cosechados. En cuanto a las clasificaciones basadas en imágenes radar multitemporales de configuración simple, se apreció que los resultados fueron mejorando a medida que se incorporaban más imágenes a la clasificación, pasando de valores de FG y Kappa de 43% a 65% y de 0.31 a 0.55 respectivamente. El mejor resultado se obtuvo con la combinación de cuatro imágenes radar adquiridas entre abril y junio. La combinación de una imagen óptica con varias escenas radar mejoró el resultado final de la clasificación, llegando a

obtener una FG de 82% e índice de Kappa de 0.75 en el mejor de los casos (combinación de Landsat 5-TM de mayo con cuatro escenas radar adquiridas entre abril y junio).

Además de evaluar la fiabilidad de las clasificaciones a nivel global, también se analizaron los resultados obtenidos a nivel de cultivo. En este caso, se vio que las clasificaciones combinando óptico-radar mejoraron significativamente la detección de algunos cultivos concretos. Si bien las imágenes ópticas tanto de mayo como de junio no conseguían discriminar bien por sí solas los cultivos minoritarios (guisante, barbecho, habas y colza), éstos se clasificaron con mayor precisión en las combinaciones óptico-radar.

Como conclusión se puede afirmar que las clasificaciones mejoraron al combinar una única imagen óptica con varias escenas radar de configuración simple. Asimismo, estos resultados confirmaron la importancia de la multitemporalidad y la fecha de adquisición de las imágenes de cara a discriminar adecuadamente los cultivos utilizando observaciones radar.

4) Backscattering behavior of rain-fed crops along the growing season (Larrañaga et al., 2013).

Este trabajo fue publicado en el volumen 10, número 2 de la revista *IEEE Geoscience and Remote Sensing Letters* en marzo de 2013.

La multitemporalidad y la fecha de adquisición de imágenes son aspectos claves para una correcta clasificación de cultivos a partir de imágenes radar. Estudios basados en imágenes adquiridas en periodos en los que las diferencias entre cultivos no eran claras resultaron en clasificaciones con fiabilidades bajas (Del Frate et al., 2003; McNairn et al., 2009; Larrañaga et al., 2011a; Skriver 2012). Para evitar estos problemas es conveniente establecer en cada caso cuales son las fechas de adquisición óptimas, esto es, las que permiten una mejor separación y clasificación de cultivos. En cada zona, las fechas de adquisición óptimas varían en función del calendario agrícola y la evolución fenológica de los cultivos presentes en la zona. En zonas de secano es común cultivar cultivos de invierno (e.g., cereales, colza, leguminosas, etc.) que siguen un calendario agrícola similar (a excepción de algunos cultivos concretos como el girasol). El desarrollo fenológico de estos cultivos puede producir diferencias morfológicas (e.g., la elongación de los tallos o la aparición de inflorescencias) o dieléctricas (e.g., senescencia) que faciliten su separación frente al resto. Por ello, es necesario estudiar las variaciones temporales del coeficiente de retrodispersión para detectar esas fechas óptimas de adquisición.

El principal objetivo de este trabajo consistió en estudiar las variaciones temporales del coeficiente de retrodispersión (de los distintos canales de polarización) y los ratios de polarización directa y cruzada debido al estado fenológico de cada cultivo y establecer las fechas óptimas de adquisición y la mejor combinación de parámetros de entrada para una correcta separación y clasificación de cultivos. Para ello, se contó con cinco imágenes RADARSAT-2 polarimétricas adquiridas entre marzo y junio de 2010 sobre los valles de Aranguren y Egües, al este de Pamplona (Navarra), en la denominada zona de estudio 3 (Figura 1). Esta área corresponde a una zona de secano y los cultivos estudiados fueron: trigo, cebada, avena, girasol, colza, guisante, veza, pasto y barbecho. Al igual que en los casos anteriores, se

disponía del SIGPAC correspondiente al año de estudio y las inspecciones de las declaraciones de la PAC, utilizadas como verdad campo.

Una vez procesadas las imágenes, y como paso previo a la clasificación, se realizaron dos tipos de análisis: (i) multitemporal, donde se analizó la respuesta de cada cultivo en cada polarización y fecha, y (ii) de separabilidad, donde se evaluó la disimilitud estadística entre los cultivos para los diferentes canales de polarización y fechas. Para este último análisis se utilizó como medida de disimilitud la distancia de Jeffries-Matusita, que a diferencia de otras medidas de distancia, toma un rango de valores acotado y no requiere que las variables analizadas sigan distribuciones de probabilidad normales (Swain y King, 1973).

En esta ocasión, el algoritmo de clasificación que se utilizó fue el de *Random Forest* (RF) (Breiman, 2001). Estudios previos (e.g., Waske y Braun, 2009) demostraron que RF obtenía mejores resultados que otros algoritmos convencionales (e.g., MLC) al clasificar imágenes radar multitemporales debido principalmente a que los datos radar no se ajustan necesariamente a la distribución normal. Por eso y con la finalidad de analizar distintos clasificadores supervisados a lo largo de la tesis, se optó por trabajar con el algoritmo RF. Este clasificador es también supervisado y se basa en la construcción automática de múltiples árboles de decisión que clasifican individualmente cada elemento y donde la clase final se asigna por mayoría. Se realizaron varias clasificaciones a nivel de parcela: (i) utilizando imágenes de cada fecha por separado y (ii) utilizando series multitemporales de imágenes.

En el análisis previo a las clasificaciones (análisis multitemporal y de separabilidad), las polarizaciones HV y VV fueron las que mostraron una mayor sensibilidad al desarrollo de los cultivos estudiados, obteniendo los valores más altos de separabilidad. En cuanto a las fechas de adquisición, mayo y principios de junio fueron las fechas más interesantes para identificar los distintos cultivos.

En la fase de clasificación se trabajó en primer lugar considerando únicamente los coeficientes de retrodispersión en las distintas polarizaciones (σ°_{HH} , σ°_{HV} , σ°_{VH} , σ°_{VV}). En este caso se observó que al clasificar cada imagen por separado, las imágenes de mayo y junio fueron las que mejores resultados proporcionaron. Entre ellas, la escena adquirida el 5 de junio fue la mejor, con valores de FG de 67% y Kappa de 0.46. Las series multitemporales mejoraron este resultado inicial, llegando en el mejor de los casos (combinando imágenes de mayo y junio) a alcanzar una FG y Kappa de 79% y 0.67 respectivamente. Este resultado, se considera muy satisfactorio y más aun teniendo en cuenta que los cultivos de cereal se clasificaron independientemente. En una fase posterior, se incluyeron los ratios de polarización directa y cruzada en el esquema de clasificación inicial, pero en este caso no se observó una mejora significativa en el resultado final.

Los resultados obtenidos demostraron, una vez más, la importancia de la fecha de adquisición de imagen y la polarización del sensor para poder identificar y clasificar satisfactoriamente los cultivos. El algoritmo de clasificación *Random Forest* resultó ser un clasificador adecuado para trabajar con observaciones multitemporales radar.

5) On the added value of quad-pol data in a multi-temporal crop classification framework based on RADARSAT-2 imagery (Larrañaga y Álvarez-Mozos, 2016).

Este último trabajo ha sido recientemente publicado en el volumen 8 de la revista *Remote Sensing*, en abril de 2016.

Los datos quad-pol pueden clasificar con éxito muchos tipos de siempre y cuando la fecha de adquisición de las imágenes sea la adecuada cultivo (Del Frate et al., 2003; Jiao et al., 2014; Larrañaga et al., 2013). Las imágenes deben ser adquiridas en fechas en las que los cultivos se encuentren plenamente desarrollados o, al menos, presenten diferencias suficientes para poder ser discriminados. Además, puede haber variaciones en las fechas de siembra y cosecha de cada cultivo y éstos pueden seguir un desarrollo fenológico diferente con eventos (e.g., aparición de inflorescencias, senescencia, etc.) que permitan su mejor identificación. En este sentido, hay muchos estudios que inciden en la importancia de utilizar observaciones multitemporales para poder identificar adecuadamente los distintos cultivos (De Wit y Clevers, 2004; Larrañaga et al., 2013; Sabour et al., 2007; Skriver, 2012; Susan Moran et al., 2012; Wang et al., 2010).

Se ha demostrado que los sensores polarimétricos o quad-pol ofrecen una mayor capacidad de clasificación de cultivos que los de polarización simple. Sin embargo, cuentan también con una serie de inconvenientes a considerar. En concreto, debido a la complejidad y magnitud de sus datos, generan y almacenan un gran volumen de información, de forma que se reduce la cobertura espacial de las adquisiciones y se alarga su periodo de revisita, limitando posibilidad de obtener observaciones multitemporales muy frecuentes. Por este motivo, se considera necesario evaluar el valor añadido de los datos quad-pol en un marco de clasificación de cultivos multitemporal basado en imágenes radar.

En Larrañaga et al. (2013) se procesaron cinco escenas RADARSAT-2 polarimétricas, adquiridas entre marzo y julio del 2010 sobre la zona este de Pamplona, la denominada zona de estudio 3 (Figura 1), para investigar las fechas óptimas para la identificación de los cultivos. Partiendo de los resultados de ese trabajo se optó por utilizar las tres escenas RADARSAT-2 polarimétricas (adquiridas entre mayo y junio del 2010) que mejores resultados obtuvieron (FG del 82%). se analizó si esos resultados eran comparables con los obtenidos usando únicamente datos dual-pol, o de manera opuesta, si los datos quad-pol representados en otra base de polarización o la inclusión de diferentes parámetros polarimétricos conducía a la mejora de los resultados de la clasificación. La zona de estudio fue la misma que en Larrañaga et al. (2013), la zona de estudio 3 (Figura 1) y los cultivos estudiados fueron también los mismos (trigo, cebada, avena, girasol, colza, guisante, veza, pasto y barbecho).

Se calcularon los coeficientes de retrodispersión (σ^0) en distintas bases de polarización (lineal, circular y elíptica), así como diferentes parámetros polarimétricos ($|\rho_{HHVV}|$, Φ_{HHVV} , H , A , α , α_1 , y los parámetros derivados de la descomposición de Pauli), seleccionados en base a estudios previos (Loosvelt et al., 2012a; 2012b; Lopez-Sanchez et al., 2011). Una vez analizada la separabilidad y realizado un análisis descriptivo de todos los parámetros a estudiar, se diseñaron diferentes esquemas de clasificación supervisada a nivel de parcela. Como en Larrañaga et al. (2013) el algoritmo de clasificación empleado fue el de *Random Forest* (RF), pero en este caso se siguió un procedimiento para equilibrar el tamaño de las áreas entrenamiento (*training sets*) de cada cultivo. Para ello, se sobremuestrearon las clases

minoritarias generando sintéticamente muestras adicionales hasta igualar el tamaño de la clase mayoritaria.

Los resultados obtenidos utilizando datos dual-pol se compararon con aquellos obtenidos con los datos quad-pol (en distintas bases de polarización), así como con los obtenidos con las configuraciones donde se añadían distintos parámetros polarimétricos. Los datos dual-pol obtuvieron unos resultados satisfactorios, con valores de FG y Kappa de 79% y 0.69 respectivamente, similares a los alcanzados con datos quad-pol en base de polarización lineal. Las configuraciones quad-pol en polarización circular y elíptica produjeron resultados peores. La inclusión de los parámetros polarimétricos, en particular el coeficiente de correlación ($|\rho_{HHVV}|$) y la diferencia de fase (ϕ_{HHVV}), mejoraron los resultados obtenidos alcanzando una FG y Kappa de 86% y 0.79 al utilizar todos los parámetros polarimétricos como variables predictivas en la clasificación. Estas mejoras se correspondieron con la mejor identificación de algunos cultivos en concreto, aunque los cultivos mayoritarios (cereales, colza y girasol) obtuvieron también una buena fiabilidad con los datos dual-pol y las mejoras observadas en estos casos fueron escasas.

Como conclusión se puede afirmar que, conociendo el calendario agronómico y las fechas óptimas para identificar los cultivos, las observaciones multitemporales dual-pol que operan en la banda-C pueden utilizarse de forma operativa para clasificar cultivos.

RECOPIACIÓN DE LOS TRABAJOS COMPLETOS

Clasificación de cultivos en la zona media de Navarra mediante imágenes radar polarimétricas

Crop classification in central Navarre using polarimetric radar data

A. Larrañaga¹, L. Albizua¹ y J. Álvarez-Mozos²
alarranaga@tracasa.es

¹ Tracasa. Departamento de Sistemas de Información Territorial. C/ Cabárceno, 6. 31621 Sarriguren. Navarra

² Universidad Pública de Navarra. Departamento de Proyectos e Ingeniería Rural. Los Tejos. Arrosadía, s/n. 31006 Pamplona. Navarra

Recibido el 8 de marzo de 2010, aceptado el 6 de octubre de 2010

RESUMEN

Navarra lleva años empleando la técnica de clasificación supervisada de imágenes multiespectrales de satélite para la realización de la estadística agraria. La cubierta nubosa, muy habitual en esta zona, limita e incluso imposibilita el uso de imágenes ópticas para este fin. Los sensores radar representan una alternativa interesante, dado que a las longitudes de onda que trabajan, la cobertura nubosa es transparente, por lo que la nubosidad no supone ningún tipo de limitación para su empleo. Por otro lado, los sensores radar de nueva generación (por ejemplo ALOS/PALSAR o RADARSAT-2), incorporan mejoras importantes respecto a sus predecesores (ERS-1/-2 o RADARSAT-1). En lo que respecta a la clasificación de cultivos, los sensores radar que adquieren imágenes en múltiples polarizaciones resultan especialmente interesantes.

El principal objetivo de este trabajo es evaluar la viabilidad del empleo de observaciones de teledetección radar de polarización múltiple en la clasificación de cultivos de la zona media de Navarra. Para ello, se han utilizado dos imágenes ALOS/PALSAR. Una vez realizado un detallado análisis polarimétrico, se han obtenido las firmas o signatures de los distintos cultivos de secano y de regadío por separado y se ha realizado una clasificación supervisada. La clasificación obtenida se ha comparado con la verdad campo resultando en un índice Kap-

ABSTRACT

Supervised classifications using optical remote sensing data have been used in the region of Navarre (Spain) for many years to obtain data for the elaboration of the annual crops statistics. However, cloud cover very frequent in this area limits and even prevents the use of optical data for this scope. Radar remote sensing represents an interesting alternative, since at its wavelengths, the cloud cover is transparent; not implying any limitation. Furthermore, the new generation of radar sensors (ALOS/PALSAR and RADARSAT-2 for example), incorporate significant improvements over their predecessors (or ERS-1/-2 RADARSAT-1). Finally, for crop classification, radar sensors that acquire images in multiple polarizations are particularly interesting.

The main objective of this study was to evaluate the feasibility of polarimetric radar observations for crop classifications in central Navarre. For this, two ALOS/PALSAR observations have been used. A detailed polarimetric analysis, polarimetric signatures of different crops under dryland and irrigation conditions were the previous step to the supervised classification performed. The result crop classification was compared with reference ground data, obtaining an overall Kappa and accuracy of 0.52 and 85% respectively.

pa y fiabilidad global de 0,52 y 85% respectivamente.

PALABRAS CLAVE: teledetección radar, polarimetría, clasificación supervisada, clasificación por parcela, retrodispersión.

KEY WORDS: radar remote sensing, polarimetry, supervised classification, parcel-based classification, backscatter.

AANTECEDENTES

Los sensores radar emiten un pulso de radiación hacia la superficie terrestre y reciben el pulso de retorno (o retrodispersión). La señal de retorno que capta el sensor depende de las características de las cubiertas observadas y de la configuración del propio sensor. Los parámetros principales de la configuración de un sensor son la frecuencia o banda en que trabaja, el ángulo de incidencia que forma el haz de radiación emitido con la vertical y la polarización de la radiación emitida y recibida por el sensor (Ulaby y Elachi, 1990). La polarización hace referencia a la orientación del campo eléctrico de la radiación electromagnética, que básicamente puede ser vertical (V) u horizontal (H). Por lo tanto, el canal de un sensor que emite y recibe en la polarización H se denomina HH, mientras que uno que emite en V y recibe en H se denomina VH.

Los primeros sensores radar que se pusieron en órbita (ERS-1/-2, RADARSAT-1 y JERS) fueron (salvo alguna excepción) sensores de configuración simple. Éstos, trabajaban en una única banda (frecuentemente la banda C, con una frecuencia cercana a los 5 GHz) y con una única polarización (generalmente directa, HH o VV). En consecuencia, estos sensores proporcionan un único canal por cada imagen adquirida, lo que ha supuesto una limitación de cara a su uso para la clasificación de cubiertas (Lee *et al.*, 2001).

Los sensores radar de nueva generación (por ejemplo ALOS/PALSAR o RADARSAT-2) incorporan mejoras importantes. Entre otras, resulta especialmente interesante la capacidad de los sensores de adquirir información en múltiples polarizaciones. La adquisición simultánea de imágenes en varias polarizaciones resulta útil para interpretar y clasificar el terreno dado que se añaden canales con información adicional interesante que permiten caracterizar las propiedades físicas de la superficie observada de for-

ma mucho más completa. Esto ha hecho que en los últimos años se estén empleando este tipo de observaciones en diferentes aplicaciones como en agricultura, silvicultura, hidrología etc. (Ouarzeddine *et al.*, 2007).

Como ya se ha comentado, la retrodispersión es función de la configuración del sensor, pero también de características de las cubiertas como su geometría y comportamiento dieléctrico. Por consiguiente, son observaciones que ofrecen una información distinta y complementaria a la obtenida por los sensores ópticos.

Los radares polarimétricos recogen la completa caracterización de la dispersión en todas las configuraciones de polarización (HH, VV, HV y VH). En cada polarización el sensor recibe la amplitud y fase del pulso de radiación proveniente del terreno, traduciéndose en un total de ocho canales distintos. Con esta información de partida es posible calcular parámetros interesantes como los ratios entre diferentes canales, su grado de correlación (o coherencia) o las diferencias entre las fases. También es posible emplear algoritmos de descomposición, que permiten descomponer las observaciones en parámetros que ofrecen una interpretación física de la interacción ocurrida (por ejemplo dispersión superficial, dispersión de volumen o doble rebote) (Freeman y Durden, 1992; Lee *et al.*, 1999; Ouarzeddine *et al.*, 2007). Las descomposiciones se pueden utilizar para interpretar la naturaleza de las cubiertas e incluso realizar clasificaciones no supervisadas (Alberga, 2007; Rodrigues *et al.*, 2003). Aunque en esta línea se hayan producido avances significativos, se ha visto que lo mejor es hacer un uso combinado de los algoritmos de descomposición y de herramientas estadísticas para realizar clasificaciones de terreno de forma más fiable (Cloude y Pottier, 1997; Ouarzeddine *et al.*, 2007).

El principal objetivo de este trabajo es evaluar la viabilidad del empleo de observaciones de teledetección radar de polarización múltiple



Figura 1. La zona sombreada indica el área de estudio. Este área está definida por la zona común de las dos imágenes ALOS PALSAR utilizadas.

en la clasificación de cultivos de la zona media de Navarra.

INFORMACIÓN DE PARTIDA

El estudio se ha llevado a cabo en la zona media de la Comunidad Foral de Navarra (España) (Fig. 1). Las zonas agrícolas de interés de este área están ocupadas por cultivos herbáceos de secano y de regadío, siendo mayoritarios los primeros (Fig. 2a, Tabla 1).

Se ha trabajado con dos imágenes radar de primavera del año 2007 (Fig. 2b), captadas por el satélite de observación japonés ALOS. Dicho satélite, lanzado en 2006 por la Agencia Espacial Japonesa (JAXA), está compuesto de 3 sistemas independientes (PRISM: Panchromatic Remote-sensing Instrument for Stereo Mapping, AV-NIR-2: Advanced Visible and Near Infrared Ra-

	Superficie (ha)
Secano	53.989
Regadío	3.147
Total	57.135

Tabla 1. Superficie de las parcelas agrícolas clasificadas.





Figura 2. a) Parcelas agrícolas del SIGPAC de secano (en verde) y de regadío (de rosa) que se han clasificado. b) Imagen de ALOS de mayo en representación de Pauli.

diometer-2nd generation, PALSAR: Phased Array type L-band Synthetic Aperture Radar) pudiéndose adquirir simultáneamente imágenes ópticas e imágenes radar con diversas resoluciones y coberturas. JAXA tiene definido un plan de adquisición a partir de criterios climáticos y con el objetivo de crear un archivo mundial de imágenes complementarias. Esta estrategia de adquisición está establecida para los próximos años y es prioritaria sobre el conjunto de otras peticiones (a excepción de las adquisiciones urgentes y puntuales que podrían surgir para el seguimiento de grandes catástrofes).

El sensor PALSAR es un Radar de Apertura Sintética que trabaja en la banda L y es capaz de adquirir datos de hasta 10 m de resolución con ángulos de incidencia entre 20° y 55°. Tiene cuatro modos de adquisición (cada uno de ellos con una determinada resolución, cobertura y polarización), cada uno de los cuales está activo durante un ciclo completo de adquisición de 46 días.

Las imágenes captadas por PALSAR son muy interesantes en cuanto a resolución, modos de adquisición e incluso desde el punto de vista económico. No obstante, presentan una serie de limitaciones a tener en cuenta:

- Tal y como se ha comentado anteriormente, presenta problemas en cuanto a su disponibilidad y dificultades para una programación específica.
- El modelo de ortorrectificación no está incorporado en los softwares comerciales utilizados (aunque existen programas gra-

ALOS		
Fecha adquisición	25-III-2007	10-V-2007
θ (centro escena)	23,873°	
Sensor	PALSAR	
Banda	L (1,27 GHz)	
Modo adquisición	Polarimétrico	
Órbita	Ascendente	
Tamaño píxel en slant range (m)	9*4 (rango*azimut)	

Tabla 2. Características de las imágenes ALOS/PALSAR utilizadas. θ indica el ángulo de incidencia.




Figura 3. Detalle del nivel de precisión del SIGPAC utilizado.

tuitos que permiten hacerlo, no obstante presentan importantes limitaciones).

Las características de las dos imágenes utilizadas en este estudio se detallan en la Tabla 2.

Como información auxiliar se ha utilizado el SIGPAC 2007, que nos garantiza un ajuste muy preciso de la superficie agrícola. El SIGPAC contiene información detallada de los usos de cada parcela (Fig. 3). Además también se cuenta con información sobre las inspecciones de las declaraciones PAC que se utilizan como verdad campo (VC), junto con visitas a campo diseñadas específicamente para tener suficiente representatividad de los cultivos. El tamaño de las parcelas de secano y regadío varían entre 300 y 300.000 m² y 600 y 100.000 m² respectivamente aunque la mayoría de las parcelas tanto de secano como de regadío oscilan entre los 2.000 y 4.000 m² siendo las parcelas de regadío algo más pequeñas. Toda esta información de verdad campo se ha utilizado para seleccionar las bandas más importantes y para crear las firmas espectrales de los cultivos a clasificar.

METODOLOGÍA Y RESULTADOS

La Figura 4 muestra el flujo de trabajo llevado a cabo.

Preproceso

En esta primera fase, se ha realizado el filtrado del ruido speckle y se han creado nuevas bandas a partir de la información original filtrada de cada imagen (Fig. 5). El filtro utilizado ha sido el de Lee Adaptativo, con un tamaño de ven-

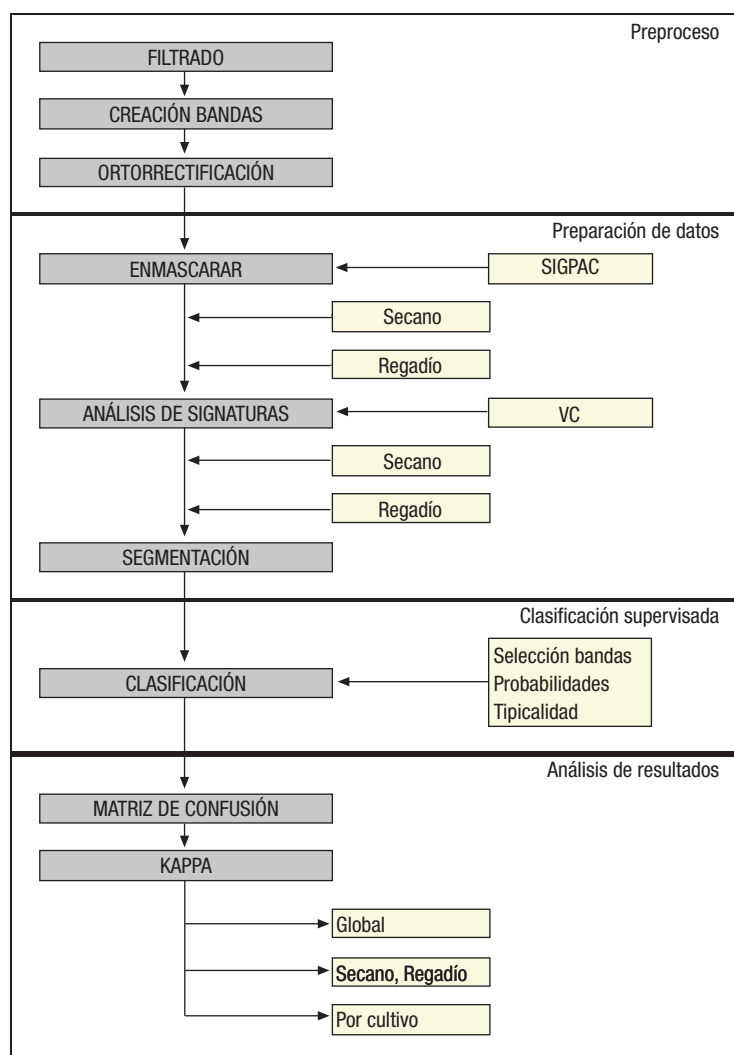


Figura 4. Flujo de trabajo.

tana de 3×3 . Las bandas creadas (σ°_{HH} , σ°_{HV} , σ°_{VV} , Span $\sigma^{\circ}_{HV}/\sigma^{\circ}_{VV}$, $\sigma^{\circ}_{RR}/\sigma^{\circ}_{RL}$, $|\rho_{HHVV}|$, ϕ_{HHVV} , H, α y A) pueden tener una interpretación física útil y han sido seleccionadas debido a que en estudios previos (Quegan *et al.*, 2003; Skriver *et*

al., 2005) han proporcionado resultados satisfactorios.

El coeficiente de retrodispersión (σ°) para cada polarización (HH, VH y VV), representa el ratio entre la potencia total recibida y la emitida ini-




Figura 5. Representación de la fase de preproceso.

cialmente. Este coeficiente puede tomar valores diferentes en cada canal de polarización y esas diferencias se pueden interpretar en función de los 3 principales mecanismos de dispersión: (1) simple o especular, (2) doble o de rebote y (3) de volumen, que se relacionan con las características de las distintas cubiertas del terreno (agua, suelo urbano, forestal e incluso distintos cultivos, etc.). De esta forma y en términos generales se dice que σ_{HV}° es mayor para zonas forestales y urbanas debido a la dispersión por volumen, así como $\sigma_{HH}^{\circ} < \sigma_{VV}^{\circ}$ para dispersores orientados verticalmente (árboles, tallos, etc.) y viceversa para dispersores orientados horizontalmente. Sin embargo, el fenómeno de la extinción diferencial provoca que cultivos con elementos orientados verticalmente, además de poder tener mayor σ_{VV}° , también produzcan una mayor extinción (en dB/m) de la onda polarizada verticalmente a su paso por el medio. Dependiendo del tipo de escena, esto puede causar que la retrodispersión del canal HH (teniendo en cuenta el suelo y la interacción con la planta) sea mayor que la del VV, debido a la mayor atenuación de la onda polarizada verticalmente. Además de esto, tal y como se ha mencionado en el apartado de antecedentes y tal y como demuestran otros estudios (Quegan *et al.*, 2003; Skriver *et al.*, 1999), la señal de retorno del radar depende del ángulo de incidencia local que es función de la geometría de la adquisición y del relieve. Por lo tanto, se ha calculado el ángulo de incidencia local para cada píxel (a partir de los metadatos de la imagen y de un MDT de la zona) y con este ángulo se ha obtenido el coeficiente de retrodispersión (σ°) de cada canal de polarización.

El ratio de polarización cruzada tanto lineal como circular ($\sigma_{HV}^{\circ}/\sigma_{VV}^{\circ}$ y $\sigma_{RR}^{\circ}/\sigma_{RL}^{\circ}$) se utiliza para distinguir vegetación y suelo desnudo, así como distintos tipos de cultivos (Quegan *et al.*, 2003; Skriver *et al.*, 2005). La potencia total (Span) representa la suma de la potencia recibida por los cuatro canales y se suele utilizar en procesos de clasificación de la imagen ya que da una buena representación de la distribución espacial (contornos, zonas homogéneas, etc.) relacionados con el uso del terreno (Touzi *et al.*, 1992).

El módulo del coeficiente de correlación de polarización directa ($|\rho_{HHVV}|$), tal y como indica su nombre, representa la correlación entre los dos canales de polarización directa. Este parámetro se suele emplear para detectar depolari-

zación, cuando la dispersión de superficie es predominante su valor se acerca a 1 mientras que en cubiertas donde la dispersión de volumen predomina su valor es cercano a 0.

La diferencia de fase entre los dos canales co-polarizados (ϕ_{HHVV}), representa el número de reflexiones o rebotes que sufre la onda, un valor de 0° corresponde a una única reflexión (o un número impar) y representa la dispersión superficial, mientras que un valor de 180° corresponde a rebotes dobles (o pares) que ocurren con reflectores de esquina. En los casos de superficies con vegetación donde predomina la dispersión por volumen, el valor de la diferencia de fase co-polarizada puede oscilar entre los -180° y 180° dependiendo del tipo de vegetación y de la configuración del sensor.

Los tres últimos parámetros que quedan por mencionar, (entropía, alfa y anisotropía) reúnen la información polarimétrica y la descomponen en términos de los mecanismos de retrodispersión que se producen en las cubiertas, lo que está directamente relacionado con su naturaleza (Cloude and Pottier, 1996). La entropía (H) representa el grado de aleatoriedad o desorden estadístico de la dispersión. Varía entre 0, reflexiones de primer orden, y 1, mezcla aleatoria de mecanismos de reflexión. El ángulo alfa proporciona un valor relativo al mecanismo de retrodispersión dominante, oscila entre 0° , dispersión superficial y 90° , reflexión de esquina, con valores intermedios 45° ilustrando la dispersión de volumen. Por último, la anisotropía (A) cuantifica la proporción entre los dos mecanismos de dispersión no dominantes. Su valor varía entre 0 y 1 y da idea de la homogeneidad de la cubierta; valores bajos corresponden a cubiertas homogéneas y viceversa.

Las dos imágenes se han ortorectificado en el sistema de referencia WGS84, UTM Huso 30, remuestreando las imágenes por medio del algoritmo de convolución cúbica a tamaño de píxel de 10 m. El modelo digital de terreno (MDT) utilizado ha sido de 5 m de resolución.

Preparación de datos

En una segunda fase, se han eliminado los estratos del SIGPAC que no interesan en este estudio, manteniendo solamente la tierra arable o

	σ_{HH}°	σ_{HV}°	σ_{VV}°	Span	$\sigma_{HV}^{\circ}/\sigma_{VV}^{\circ}$	$\sigma_{RR}^{\circ}/\sigma_{RL}^{\circ}$	$\rho_{(HHVV)}$	$\theta_{(HH-VV)}$	α	H	A
σ_{HH}°	—	0,39	0,90	0,97	-0,10	-0,09	0,12	0,00	-0,12	-0,20	0,06
σ_{HV}°		—	0,39	0,50	0,54	0,48	-0,36	0,00	0,44	0,42	-0,23
σ_{VV}°			—	0,96	-0,15	-0,13	0,16	0,00	-0,17	-0,22	0,02
Span				—	-0,05	-0,04	0,08	0,00	-0,08	-0,15	0,01
$\sigma_{HV}^{\circ}/\sigma_{VV}^{\circ}$					—	0,85	-0,75	0,00	0,88	0,86	-0,37
$\sigma_{RR}^{\circ}/\sigma_{RL}^{\circ}$						—	-0,91	0,00	0,95	0,90	-0,20
$\rho_{(HHVV)}$							—	0,00	-0,94	-0,90	0,05
$\theta_{(HH-VV)}$								—	0,00	0,00	0,00
α									—	0,95	-0,16
H										—	-0,24
A											—

Tabla 3. Matriz de correlación de las bandas estudiadas. En negrita se indican las bandas más correlacionadas.

parcelas agrícolas que incluyen los cultivos herbáceos de secano y de regadío (Fig. 2).

Con el fin de seleccionar las bandas más significativas, se han calculado las matrices de correlación (Tabla 3), se han analizado las firmas de la verdad campo de secano y regadío de cada imagen (Fig. 6) y finalmente se ha estudiado la separabilidad entre las bandas generadas (Fig. 7). Los valores de los parámetros estudiados en los gráficos de firmas (Fig. 6), están reescalados entre 0 y 100. Los valores mínimo y máximo utilizados para reescalar cada una de las variables estudiadas son los siguientes: de -180° a 180° para la diferencia de fase, de 0° a 90° para el ángulo alfa, de 0 a 0,5 los coeficientes de retrodispersión de polarización directa (HH y VV), de 0 a 0,1 el coeficiente de retrodispersión de polarización cruzada (HV) y de 0 a 1 el resto de variables estudiadas. Los resultados de estos tres análisis se han utilizado para seleccionar las bandas más interesantes para clasificar los cultivos.

La matriz de correlación (Tabla 3), muestra que la potencia total (Span) presenta una alta correlación con los coeficientes σ° de polarización directa. Tanto la entropía como el ángulo alfa muestran una gran correlación con los ratios de polarización cruzada lineal y circular ($\sigma_{HV}^{\circ}/\sigma_{VV}^{\circ}$ y $\sigma_{RR}^{\circ}/\sigma_{RL}^{\circ}$). También presentan una alta correlación entre sí la entropía y el ángulo alfa así como los ratios de polarización cruzada lineal y circular. El coeficiente de correlación de polarización directa ($|\rho_{HHVV}|$), también muestra una alta correlación, aunque negativa, con los ratios de polarización cruzada lineal y circular, la entropía y el ángulo alfa. La diferencia de fase (ϕ_{HHVV}) no está correlacionada con ninguna de las bandas, proba-

blemente debido al amplio rango de valores de ϕ_{HHVV} que pueden tomar las cubiertas vegetales. Por último, mencionar que la anisotropía tampoco muestra una buena correlación con ninguno de los parámetros estudiados.

Estudios anteriores realizados en Navarra (Leránz y Albizua, 2001) demostraron que al estratificar el territorio, se reducía la variabilidad del carácter estudiado, mejorando así las estimaciones obtenidas. En este trabajo, se ha seguido la estratificación propuesta en dicho estudio con lo que los cultivos de secano y de regadío se separan en distintos estratos.

Los cultivos de trigo, cebada y avena, tanto de secano como de regadío, muestran un comportamiento muy similar (Fig. 6), de modo que se han unido estas tres clases en una única clase (denominada CEREAL). En cuanto a los cultivos de regadío, destacan el girasol y el guisante ya que presentan una firma bastante diferente al del resto de los cultivos. En el caso de estos dos cultivos es muy probable que el suelo se encuentre aún desnudo en las fechas de adquisición de imágenes, por lo que el valor del coeficiente de correlación es alto y los ratios de polarización cruzada son bajos. De marzo a mayo, tanto en los cultivos de secano como en los de regadío se aprecia, en general, un ligero ascenso de los valores de los ratios de polarización cruzada así como un descenso de los valores del coeficiente de correlación debido a que al estar el cultivo más desarrollado, la dispersión por volumen aumenta.

La separabilidad entre cultivos, se ha calculado para cada banda a partir de los datos de firmas generados.

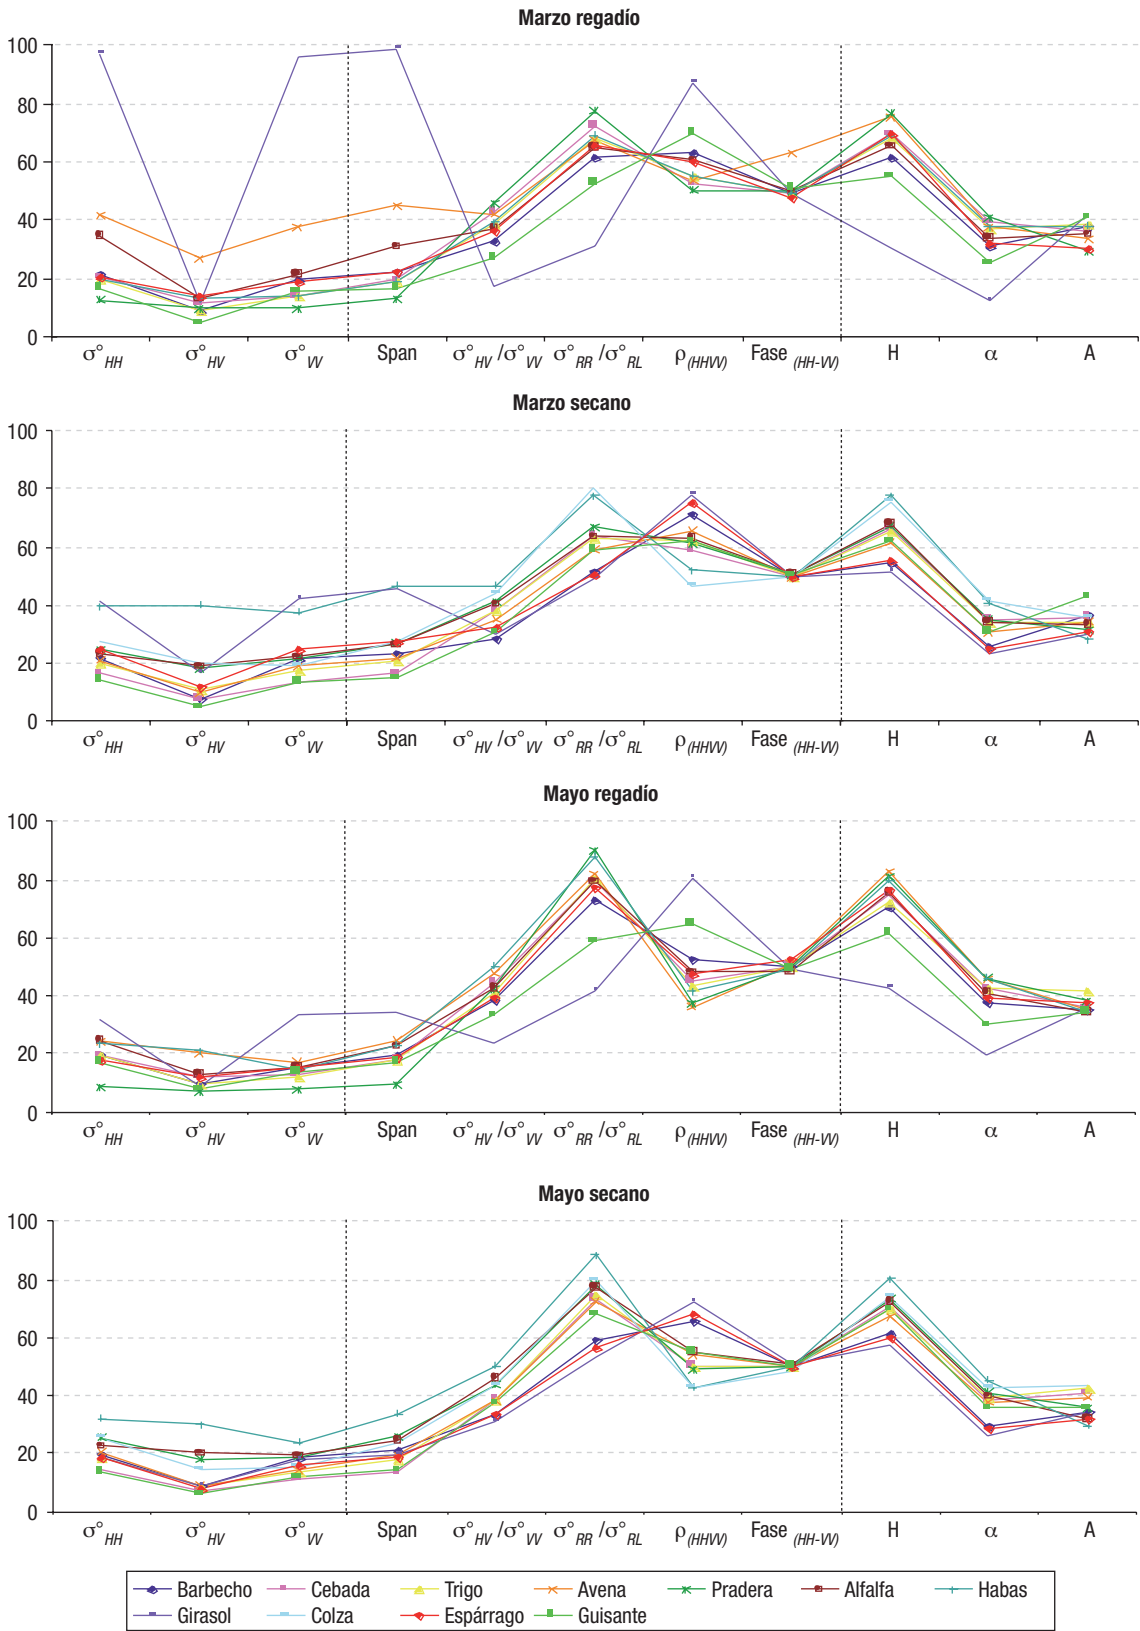


Figura 6. Análisis de firmas, los valores de los distintos parámetros están normalizados.

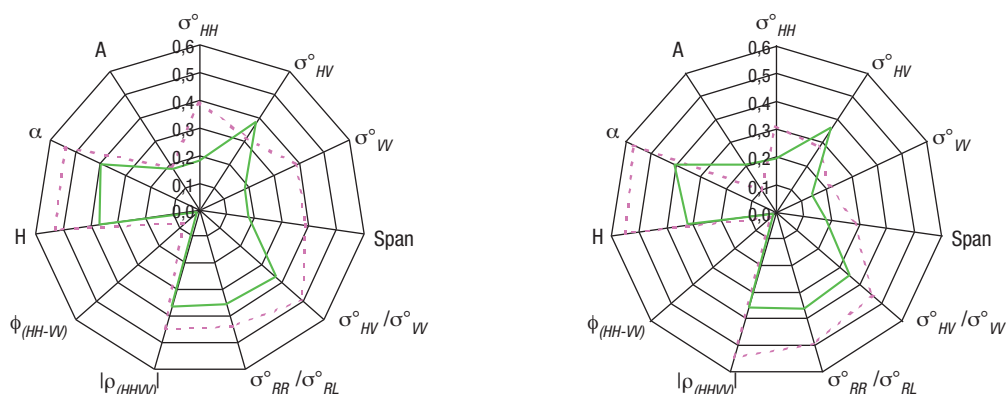


Figura 7. Separabilidad de las bandas de las imágenes de marzo (izquierda) y mayo (derecha). Las líneas continuas representan los cultivos de secano mientras que las discontinuas los de regadío.

$$\text{Separabilidad} = \frac{\chi_{\text{cultivo1}} - \chi_{\text{cultivo2}}}{\sigma_{\text{cultivo1}} - \sigma_{\text{cultivo2}}}$$

donde, χ representa el valor medio para cada clase de un determinado parámetro y σ su desviación típica (Lee *et al.*, 2001). En las siguientes figuras, se representa la separabilidad media de cada banda para los cultivos de secano y regadío, y para cada imagen.

En general (excepto para valores de sigma de polarizaciones cruzadas), los cultivos de regadío presentan mayor separabilidad que los de secano (Fig. 7). Las bandas que mayor separabilidad presentan, tanto en secano como en regadío son: H, α , $|\rho_{HHVV}|$, $\sigma_{HV}^{\circ}/\sigma_{VV}^{\circ}$ y $\sigma_{RR}^{\circ}/\sigma_{RL}^{\circ}$.

Una vez analizadas las signaturas, las matrices de correlación y la separabilidad, se ha decidido seleccionar las siguientes bandas para clasificar los cultivos: σ_{HH}° , σ_{HV}° , α , $|\rho_{HHVV}|$, $\sigma_{HV}^{\circ}/\sigma_{VV}^{\circ}$ y $\sigma_{RR}^{\circ}/\sigma_{RL}^{\circ}$.

Varios autores (Alberga, 2007; Quegan *et al.*, 2003; Dong *et al.*, 2001) han observado que la clasificación por parcela da mejores resultados que la clasificación por píxel. En este trabajo, se ha realizado una segmentación utilizando como objetos las parcelas agrícolas obtenidas del SIG-PAC correspondiente a la zona de estudio. Posteriormente, a cada una de las parcelas se les ha asignado el valor medio de sus píxeles en cada una de las bandas.

Clasificación supervisada

Rodrigues *et al.* (2003) ya demostraron que las clasificaciones supervisadas daban mejores resultados que las no supervisadas. Por lo tanto

en este trabajo se ha empleado el algoritmo de clasificación supervisada de máxima verosimilitud. Este clasificador permite asignar cada objeto (en este caso parcela) a una determinada clase según una función de probabilidad.

Previamente al proceso de clasificación se han asignado probabilidades a priori (o peso) a cada uno de los cultivos a clasificar. Estas probabilidades se han obtenido a partir de los datos de Coyuntura Agraria 2007. Esta asignación ayuda a discriminar mejor entre aquellos cultivos con respuesta similar ya que desplaza a un lado u otro las distribuciones de probabilidad en función del valor de probabilidad «a priori» asignado.

El resultado de la clasificación ha consistido en la asignación de cada parcela a una determinada clase asociándose además el valor de tipicidad con que ha sido asignada. Este valor permite conocer el grado de fiabilidad de pertenencia a esa clase. Así, tipicidades altas indican probabilidad de pertenencia a esa clase elevada y viceversa.

Análisis de resultados

Se calcula la matriz de confusión, el índice Kappa global y de cada cultivo (Tablas 4 y 5).

La colza, no se cultiva en los campos de regadío, por eso aparece en gris en la Tabla 4. La alfalfa tanto de secano como de regadío no se ha clasificado correctamente. Esto puede deberse a que se disponía de poca muestra de este cultivo y además la alfalfa, suele recibir varios cortes a lo largo de su ciclo productivo. En esta zona de estudio en concreto, la alfalfa que se

	Sec. + Reg.	Secano	Regadío
Fiabilidad global	0,85	0,87	0,61
Kappa global	0,52	0,54	0,34
Kappa por cultivo			
Barbecho	0,53	0,55	0,16
Cereales	0,52	0,52	0,33
Pradera	—	—	—
Alfalfa	0,09	0,08	0,26
Habas	0,91	0,91	0,74
Girasol	0,68	0,51	0,81
Colza	0,29	0,29	
Espárrago	0,18	0,78	0,02
Guisante	0,88	0,57	1,00

Tabla 4. Resultados obtenidos, globales y por cultivo.

siembra en septiembre suele recibir cuatro o cinco cortes mientras que la alfalfa que se siembra en primavera, recibe tres o cuatro cortes durante el verano. Esto hace que sea un cultivo muy heterogéneo por lo que la firma obtenida para la alfalfa es poco precisa y, en consecuencia, no se clasifica adecuadamente. La pradera, otra clase que presenta bastante heterogeneidad, tampoco se ha clasificado bien y se confunde principalmente con los cereales, > 70% de las praderas se han clasificado como cereales (Tablas 4 y 5).

Los cultivos mayoritarios de la zona y por lo tanto los que mayor probabilidad a priori tienen son los cereales y se han clasificado adecuadamente, más del 90% se han clasificado en la clase que les correspondía. Los cultivos minoritarios, la colza, el espárrago y los guisantes, que

quedan peor clasificados, se confunden con cultivos mayoritarios como los cereales y el barbecho (Tabla 5).

En términos generales, los cultivos de secano se han clasificado mejor que los de regadío (Tabla 4). Esto puede deberse a que (1) la muestra de cultivos de regadío era menor que la de secano, (2) el tamaño medio de las parcelas de regadío también era inferior a las de secano y (3) se sabe, gracias a las visitas a campo realizadas en fechas próximas a las adquisiciones de las imágenes, que en algunas de las parcelas acababan de instalar recientemente la infraestructura para el riego, aunque mantenían un sistema de producción de secano.

La fecha en la que se adquieren las imágenes es vital en el resultado de la clasificación debi-

	Verdad campo								
	BA	Cereal	PR	AF	HA	GI	CO	ES	GU
<i>Clasificado</i>									
BA	59,78	4,13	11,63	11,48	0,11	10,83	0,00	24,39	29,51
Cereal	37,58	94,82	70,93	61,45	17,91	0,00	47,60	53,52	55,06
PR	0,17	0,15	0,00	0,00	0,36	0,00	0,00	0,00	0,00
AF	1,19	0,20	1,29	12,56	9,47	0,00	0,00	0,00	0,00
HA	0,32	0,14	0,25	0,00	54,46	0,00	0,00	0,00	0,00
GI	0,23	0,03	0,00	0,00	3,62	89,17	0,00	0,00	0,00
CO	0,46	0,15	8,17	0,00	12,28	0,00	52,40	0,00	0,00
ES	0,27	0,34	7,73	14,51	0,00	0,00	0,00	22,08	0,00
GU	0,00	0,05	0,00	0,00	0,00	0,00	0,00	0,00	15,43
Total	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00

Tabla 5. Matriz de confusión de la clasificación total (secano y regadío) en tanto por cien.

do al distinto estado de desarrollo vegetativo del cultivo. Para este trabajo se han utilizado las imágenes ALOS disponibles. Lamentablemente, no había ninguna imagen de verano por lo que se han utilizado solo imágenes de primavera.

Los cultivos de verano, no se deberían de haber incluido en la clasificación debido a que las fechas de adquisición de estas imágenes no son adecuadas para tal fin. No se disponía de ninguna otra imagen adquirida en fechas más adecuadas para clasificar los cultivos de verano.

En el caso del girasol, es importante mencionar que en Navarra, el grueso de las siembras se realiza a finales del mes de abril y a principios de mayo (fuente: ITG Agrícola). Por lo tanto, hay que interpretar con cuidado los resultados obtenidos para esta clase, dado que en marzo y mayo se habrá observado el suelo desnudo y no el cultivo en sí. En definitiva, es importante conocer el ciclo productivo de todos estos cultivos para interpretar los resultados adecuadamente.

Aún conociendo todas las limitaciones que se acaban de mencionar, el resultado final obtenido ha sido bueno. El índice Kappa global de 0,52, corresponde a una calidad buena (Kappa > 0,4) según la categorización propuesta por Landis y Koch (1977) y la fiabilidad global indica que un 85% de las parcelas se han clasificado correctamente.

CONCLUSIONES

Las principales conclusiones de este trabajo son:

- La clasificación se ha llevado a cabo utilizando clasificadores convencionales y los resultados obtenidos han sido satisfactorios (Kappa global, 0,52) y similares a los obtenidos en otros estudios que utilizan el mismo tipo de clasificador (Rodrigues *et al.*, 2003).
- Es interesante realizar un análisis previo de todas las bandas generadas y seleccionar las más importantes, ya que se pueden obtener resultados similares con menor coste computacional.
- El trigo, avena y cebada se confunden mucho debido a que la época en la que se han captado las imágenes, el desarrollo vegetativo de estos cultivos es muy parecido. Es por eso que estos tres cultivos se han

unido en una única clase. Este hecho suele ser también habitual en clasificaciones basadas en imágenes ópticas y se suele actuar de forma similar.

- Es importante conocer el calendario o ciclo productivo de los cultivos a clasificar y, a ser posible, seleccionar las imágenes en función del mismo.

Las futuras líneas de trabajo son:

- Incorporar al análisis imágenes de fechas más adecuadas para clasificar los cultivos de verano.
- Estudiar clasificadores más específicos de clasificación a nivel de objeto y para imágenes multitemporales (función discriminante y random forests).
- Analizar distintos tipos de imágenes radar (distintas bandas, ángulos de incidencia y fechas) y ver cuales son los más adecuados para este tipo de clasificación.

AGRADECIMIENTOS

Este trabajo ha sido realizado gracias a la financiación por el Ministerio de Ciencia e Innovación del Subprograma Torres Quevedo, al Fondo Social Europeo y al Proyecto CGL2007-63453/HID del Plan Nacional de I+D+i.

REFERENCIAS

- ALBERGA, A. 2007. A study of land cover classification using polarimetric SAR parameters. *International Journal of Remote Sensing*, 28(17): 3851-3870.
- CLOUDE, S. R., & POTTIER, E. 1996. A review of target decomposition theorems in radar polarimetry. *IEEE Transactions Geoscience and Remote Sensing*, 34(2): 498-518.
- CLOUDE, S. R., & POTTIER, E. 1997. An entropy based classification scheme for land applications of polarimetric SARs. *IEEE Transactions Geoscience and Remote Sensing*, 35(2): 68-78.
- DONG, Y., MILNE, A. K., & FORSTER, B. C. 2001. Segmentation and classification of vegetated areas using polarimetric SAR image data. *IEEE Trans. Geoscience and Remote Sensing*, 39(2): 321-329.
- FREEMAN, A., & DURDEN, S. L. 1992. A three component scattering model to describe polarimetric SAR data. *Proc. SPIE, Radar Polarimetry*, 1748: 213-225.

- LANDIS, J. R., & KOCH, G. G. 1977. The measurement of observer agreement for categorical data. *Biometrics*, 33: 159-174.
- LEE, J. S., GRUNES, M. R., AINSWORTH, T. L., LIJEN, D. U., SCHULER, D. L., & CLOUDE, S. R. 1999. Unsupervised classification using polarimetric decomposition and the complex Wishart classifier. *IEEE Transactions Geoscience and Remote Sensing*, 37/1(5): 2249-2258.
- LEE, K. Y., LIEW, S. C., & KWOH, L. K. 2001. Land cover classification using NASA/JPL polarimetric SAR data. *International Paper presented at the 22nd Asian Conference on Remote Sensing*.
- LERÁNOZ, A., & ALBIZUA, L. 2001. Mejoras en la estratificación para la estimación de superficies cultivadas en Navarra. *Teledetección, Medio Ambiente y Cambio Global*, pp. 91-94.
- OUARZEDDINE, M., SOUISSI, B., & BELHADJ-AISSA, A. 2007. Unsupervised classification using Wishart classifier. *Proc. of ESA POLINSAR 2007 Workshop*.
- QUEGAN, S., LE TOAN, T., SKRIVER, H., GOMEZ-DANS, J., GONZALEZ-SAMPEDRO, M. C., & HOEKMAN, D. H. 2003. Crop classification with multitemporal polarimetric SAR data. *Proc. of ESA POLINSAR 2003 Workshop*.
- RODRIGUES, A., CORR, D. G., POTTIER, E., FERRO-FAMIL, L., & HOEKMAN, D. H. 2003. Land cover classification using Polarimetric SAR data. *Proc. of ESA POLINSAR 2003 Workshop*.
- SKRIVER, H., SVENDSEN, M. T., & THOMSEN, A. G. 1999. Multitemporal C- and L- band Polarimetric Signatures of Crops. *IEEE Trans. Geoscience and Remote Sensing*, 37(5): 2413-2428.
- SKRIVER, H., DALL, J., LE TOAN, T., QUEGAN, S., FERRO-FAMIL, L., POTTIER, E., LUMSDON, P., & MOSHAMMER, R. 2005. Agriculture classification using POLSAR data. *Proc. of ESA POLINSAR 2005 Workshop*.
- TOUZI, R., GOZE, S., LE TOAN, T., LOPES, A., & MOUGIN, E. 1992. Polarimetric discriminators for SAR images. *IEEE Trans. Geoscience and Remote Sensing*, 30(5): 973-980.
- ULABY, F. T., & ELACHI, C. 1990. Eds, Radar Polarimetry for Geoscience Applications. *Artech House*.

Crop classification in rain-fed and irrigated agricultural areas using Landsat TM and ALOS/PALSAR data

A. Larrañaga, J. Álvarez-Mozos, and L. Albizua

Abstract. Multispectral optical remote-sensing systems have been the base for crop identification and monitoring for many years. However, cloud cover limits and even prevents the use of optical data for this activity. Synthetic aperture radar (SAR) sensors provide an interesting alternative to conventional multispectral classification schemes. Radar sensors can acquire data regardless of cloud cover, and their observations provide complementary information to that captured by optical sensors. The main objective of this paper is to evaluate whether the incorporation of polarimetric SAR observations to a multispectral classification scheme enhances classification results using the proposed method. With this aim, one Landsat thematic mapper scene and two ALOS/PALSAR quadrature polarization scenes acquired in 2007 were processed. The results demonstrated the ability of SAR data to improve the classification based on optical images. However, improvements were slight (an increase of around 2% in the classification's overall accuracy). The results improved significantly when barley, wheat, and oats were considered a single class, called cereals. The best results were achieved using Landsat and the two ALOS/PALSAR scenes together, obtaining an overall Kappa coefficient and accuracy of 0.67 and 90%, respectively. Probably, scenes acquired on other dates (June and July) would have yielded clearer classification enhancements.

Résumé. Les systèmes de télédétection optique multispectrale ont été à la base de l'identification et du suivi des cultures durant plusieurs années. Toutefois, le couvert nuageux limite et empêche même parfois l'utilisation des données optiques à cette fin. Les capteurs radar à synthèse d'ouverture (RSO) proposent une alternative intéressante aux approches conventionnelles de classification multispectrale. Les capteurs radar peuvent acquérir des données indépendamment de la couverture nuageuse et leurs observations fournissent une information complémentaire à celle acquise par les capteurs optiques. L'objectif principal dans cet article est de déterminer si l'intégration d'observations RSO polarimétriques dans une procédure de classification multispectrale donne de meilleurs résultats de classification en utilisant la méthode proposée. Dans cette perspective, une image TM de Landsat ainsi que deux images PALSAR/ALOS en polarisation quadruple (quad pol) acquises en 2007 ont été traitées. Les résultats ont démontré le potentiel des données RSO dans l'amélioration de la classification basée sur les images optiques. Cependant, les améliorations étaient faibles (un accroissement de 2% environ de la précision globale de classification). Les résultats obtenus étaient significativement meilleurs lorsque l'orge, le blé et l'avoine étaient considérés comme une seule classe désignée sous le thème de céréales. Les meilleurs résultats étaient obtenus en utilisant l'image de Landsat et les deux images PALSAR/ALOS ensemble, résultant ainsi respectivement en un coefficient Kappa et une précision globale de 0,67 et de 90%. Probablement que des images acquises à d'autres dates (juin et juillet) auraient donné des améliorations de classification plus marquées.

[Traduit par la Rédaction]

Este artículo ha sido eliminado por restricciones de derechos de autor.

Received 31 March 2010. Accepted 19 April 2011. Published on the Web at <http://pubs.casi.ca/journal/cjrs> on 14 October 2011.

A. Larrañaga and L. Albizua. Tracasa, Department of Earth Information Systems, Caba'rceno 6, 31621 Sarriena, Spain.

J. Alvarez-Mozos. Department of Projects and Rural Engineering, Public University of Navarre, Arrosadia s/n31006 Pamplona, Spain.

Evaluación de la viabilidad del empleo de imágenes radar multitemporales de configuración simple y de la combinación óptico-radar para la clasificación de los cultivos de secano.

Informe técnico elaborado a solicitud de la Sección de Evaluación de Recursos Agrarios del Departamento de Desarrollo Rural y Medio Ambiente del Gobierno de Navarra. Año 2011.

1. ANTECEDENTES

Los métodos convencionales de obtención de datos del territorio se basan, en general, en trabajos de campo, siempre costosos y lentos (Chuvieco, 2002). La teledetección puede facilitar esta labor, disminuyendo el esfuerzo necesario para obtener un mapa de cultivos y, por ende, su coste total.

El uso de la teledetección para la clasificación de cultivos no es nada nuevo. Desde el lanzamiento, en 1972, del primer satélite de evaluación de recursos naturales Landsat-1 se han realizado múltiples trabajos en este campo (Bauer y Cipra, 1973; Thompson, 1973; Townshend, 1984; Cuevas et al., 1988; Pedley y Curran, 1991). Todos estos trabajos iniciales se basaban en observaciones adquiridas por sensores ópticos multiespectrales.

En el caso concreto de Navarra, desde el año 1991, Trabajos Catastrales ha suministrado al Departamento de Desarrollo Rural y Medio Ambiente de Navarra la estimación de las superficies de los principales cultivos anuales obtenidos mediante técnicas de Teledetección óptica.

La fiabilidad de las clasificaciones obtenidas varía de forma dramática en función del número de imágenes con que se cuente y de su fecha de adquisición. Es importante utilizar imágenes que cubran el ciclo de los cultivos a discriminar y que además sean de periodos en los que las diferencias entre los distintos cultivos son apreciables, lo que suponen periodos muy restringidos de tiempo. Todo ello limita el número de imágenes disponibles para el estudio.

Si a esta limitación se le añade la influencia de la cubierta nubosa, que limita e incluso imposibilita el uso de las imágenes ópticas de teledetección, la técnica puede resultar

poco robusta para alcanzar los requerimientos de fiabilidad mínima de muchos trabajos.

Además, la situación actual de los satélites ópticos de observación terrestre que se han venido utilizando en las Estadísticas Agraria en los últimos años no son las más propicias. Así, de los satélites de la serie Landsat que comenzaron a lanzarse en 1972 únicamente Landsat 5, puesto en órbita en 1985, se encuentra operativo a pesar de estar fuera de su vida útil. El último satélite de la serie, Landsat 7 (1999), está actualmente fuera de servicio debido a problemas técnicos. En el caso del satélite indio IRS únicamente el IRS P6, lanzado a finales de 2003, se encuentra operativo. Anteriormente se pusieron en órbita dos satélites más, el IRS-1C y el IRS-1D, que ya no captan datos.

Una forma de solventar la escasez de imágenes y el problema de la presencia frecuente de nubes es el empleo de imágenes adquiridas por satélites que incorporan sensores radar. Los sensores de teledetección radar son sensores activos que trabajan en la región del espectro electromagnético de las microondas (longitudes de onda centimétricas). Una de las principales ventajas de estos sensores es que a las longitudes de onda que trabajan, la cobertura nubosa es transparente, por lo que la nubosidad no supone ningún tipo de limitación en este caso. Por otro lado, al ser sensores activos pueden funcionar en condiciones de oscuridad, lo cual aumenta su capacidad de funcionamiento en comparación con la de los sensores ópticos.

La resolución espacial de los sensores radar es adecuada para realizar clasificaciones. Los satélites radar tradicionales incorporan sensores de apertura sintética (SAR) que proporcionan una resolución del orden de 20 m. No obstante, los sensores SAR más recientes logran resoluciones mucho mayores, de hasta 5 m en el caso de Radarsat-2 y de 1 o 2 m en el caso de TerraSAR-X.

Cabe destacar también, que las principales agencias espaciales (ESA, CSA, NASDA, DLR) han puesto recientemente en órbita sensores de este tipo, en una clara apuesta por proporcionar observaciones polarimétricas que sirvan de base al desarrollo y puesta a punto de diferentes aplicaciones.

El presente informe, recoge parte de uno de los proyectos de I+D+i que se está desarrollando actualmente y contempla la aplicación de la tecnología radar para la clasificación de cultivos. Dicha tecnología radar una vez validada, podría contribuir a solventar las limitaciones de la teledetección óptica, empleada tradicionalmente para múltiples aplicaciones, entre ellas la estimación de superficies de cultivos.

Los principales objetivos de este trabajo han consistido en: *i)* evaluar la viabilidad del empleo de observaciones de teledetección radar en la clasificación de cultivos y *ii)* evaluar la mejora en la fiabilidad de las clasificaciones al combinar una única imagen óptica con varias escenas radar.

La situación de disponer de una única imagen óptica libre de nubes, suele darse a menudo en la zona de estudio, por lo que el trabajo se basa en un posible caso real.

2. INFORMACIÓN DE PARTIDA

2.1. Zona de estudio y los cultivos estudiados

El estudio se ha centrado en la Comarca Agraria 3 de la Comunidad Foral de Navarra y el área de trabajo ha quedado definida por la zona común de todas las imágenes utilizadas para clasificar (**Figura 1**).

El 94% de la superficie agrícola corresponde a cultivos de secano y es por eso que se han considerado únicamente este tipo de cultivos. Los cultivos de secano más importantes que han entrado a formar parte de las clasificaciones son: trigo, cebada, avena, girasol, guisante, barbecho, habas, colza y pastos.

Con el fin de utilizar las imágenes más adecuadas para clasificar, es decir, aquellas que cubren el ciclo productivo de los cultivos de interés, se muestra el calendario agronómico de estos (**Tabla 1**).




Figura 1. La zona sombreada indica el área de estudio. En la figura de detalle se indican las parcelas de secano clasificadas (gris) así como la verdad campo utilizada (negro).

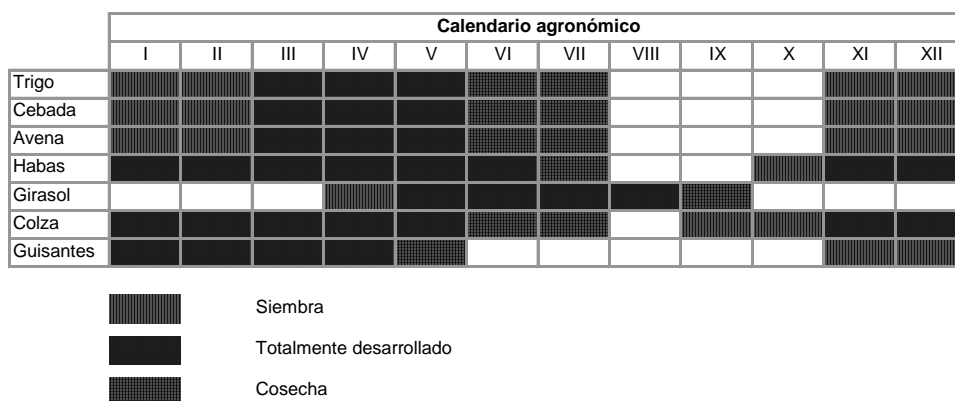


Tabla 1. Calendario agronómico de los cultivos de secano clasificados.

2.2. Imágenes ópticas y radar utilizadas

En las **tablas 2, 3 y 4**, se detallan las características principales de las imágenes ópticas y radar utilizadas.

Satélite	Fecha adquisición	Sensor	Bandas	Resolución espacial	Resolución temporal	Franja
Landsat-5	25 mayo 2009	TM	Visible e IR	30 m y 120 m (Banda 6)	16 días	185 km
	13 junio 2009					
	31 julio 2009					

Tabla 2. Características técnicas de las imágenes ópticas adquiridas por Landsat-5 TM.

Satélite	Fecha adquisición	Sensor	Banda	Polarización	Ángulo de incidencia	Resolución espacial	Resolución temporal	Franja
ERS-2	29 abril 2009	SAR	C / 5.3 GHz	VV	23° (centro escena)	30 m	35 días	100 km
	18 mayo 2009							
	16 junio 2009							
	27 julio 2009							

Tabla 3. Características técnicas de las imágenes radar adquiridas por ERS-2.

Satélite	Fecha adquisición	Sensor	Banda	Polarización	Ángulo de incidencia	Resolución espacial	Resolución temporal	Franja
ENVISAT	3 junio 2009	ASAR	C / 5.3 GHz	VV	19.2° - 26.7°	30 m	35 días	IS2 (105 km)

Tabla 4. Características técnicas de la imagen radar adquirida por ENVISAT.

2.3. Información auxiliar necesaria

Como información auxiliar se ha utilizado el SIGPAC 2009, que nos garantiza un ajuste muy preciso de la superficie agrícola. El SIGPAC contiene información detallada de los usos de cada parcela. Además también se cuenta con información sobre las inspecciones de las declaraciones PAC que se utilizan como verdad campo (VC), junto

con visitas a campo diseñadas específicamente para tener suficiente representatividad de los cultivos de interés (**Figura 1**).

3. METODOLOGÍA

3.1. Preproceso

Cuando se utilizan datos satelitales para clasificar cultivos, se realizan una serie de procesos previos a la clasificación en sí. El pre-procesamiento de las imágenes ópticas consiste en realizar correcciones geométricas, atmosféricas y radiométricas, mientras que en el caso de las imágenes radar, aparte de las correcciones radiométricas y geométricas, también se realiza el filtrado del moteado.

El moteado, es un fenómeno intrínseco de las imágenes radar y no existen unas reglas estándar que determinen el uso de un tipo y tamaño de filtro u otro. Hay que utilizar un filtro que reduzca el moteado sin llegar a disminuir la resolución espacial. En este caso, se aplicó un filtro multitemporal de tamaño de píxel 3x3, para aminorar el “ruido” o moteado.

Por último, una vez procesadas las imágenes ópticas y radar, se corregistraron para garantizar así un ajuste perfecto entre las distintas fuentes de datos.

3.2. Clasificación de la imagen

Probablemente, el clasificador de máxima verosimilitud (MLC) sea uno de los más utilizados. Sin embargo, no es el único ni tampoco el que mejores resultados obtiene para cualquier tipo de datos. Estudios realizados anteriormente, han demostrado que:

- Los datos ópticos obtienen mejores resultados al clasificar con MLC.
- Generalmente, tanto los datos radar multitemporales como la combinación óptico-radar se clasifican mejor con el algoritmo de Mahalanobis.

Se han realizado varias clasificaciones empleando o bien el algoritmo MLC o el de Mahalanobis, en función del tipo de los datos utilizados. Así, se han analizado los siguientes casos:

Sólo óptico (MLC):

- × Landsat (mayo)

- × Landsat (junio)
- × Landsat (julio)

Sólo radar (Mahalanobis):

- × ERS-2 (abril, mayo)
- × ERS-2 (abril, mayo, junio)
- × ERS-2 (abril, mayo, junio, julio)
- × ERS-2 (abril, mayo, junio) + Envisat (junio)
- × ERS-2 (abril, mayo, junio, julio) + Envisat (junio)

Óptico + radar (Mahalanobis):

- × Landsat (mayo) + ERS-2 (abril, mayo, junio) + Envisat (junio)
- × Landsat (junio) + ERS-2 (abril, mayo, junio) + Envisat (junio)

Todas las clasificaciones se han realizado a nivel de parcela y de manera supervisada. Estas parcelas, corresponden a las parcelas agrícolas obtenidas a partir del SIGPAC.

Para estudiar la precisión de cada clasificación, se han calculado una serie de parámetros estadísticos globales y para cada cultivo.

4. ANÁLISIS DE RESULTADOS

Antes de nada, hay que mencionar que en los casos en que las fechas de las imágenes ópticas y radar no coincidan, los resultados obtenidos no serán directamente comparables. Sin embargo, el objetivo de este trabajo ha sido el de evaluar la viabilidad del empleo de observaciones de teledetección radar y ver si la incorporación de las imágenes radar mejora el resultado final utilizando el clasificador más adecuado en cada caso.

4.1. Resultados a nivel global

En cada uno de los casos, se analiza la fiabilidad y el coeficiente de Kappa global:

- × La fiabilidad o precisión global, indica el porcentaje de los píxeles bien clasificados respecto al total. Uno de sus inconvenientes es que sobre estima

la bondad de la clasificación dado que no considera los errores entre las clases.

- × Kappa, es un coeficiente muy utilizado como parámetro de calidad. Es más estricto que la fiabilidad global dado que toma en consideración los elementos marginales de la matriz de confusión. Su valor da idea del porcentaje de acuerdo obtenido en la clasificación una vez eliminado la parte que se debería al azar.

4.1.1. Resultados utilizando una sola escena óptica (MLC).

La imagen de Landsat de junio ha sido la que mejores resultados ha obtenido, precisión global (OA) y Kappa de 80% y 0.70 respectivamente (**Tabla 4**). Los resultados de la escena de mayo han sido también buenos, obteniendo una OA y Kappa de 76% y 0.64. En ambos casos, el valor de Kappa se considera como bueno ya que toma valores > 0.60.

Modelo	Imágenes utilizadas	OA	Kappa
Óptico	LS_mayo	76%	0.64
Óptico	LS_junio	80%	0.70
Óptico	LS_julio	67%	0.52

Tabla 4. Fiabilidad global (OA) y coeficiente Kappa de las distintas imágenes ópticas clasificadas con MLC.

De las tres escenas Landsat estudiadas, la imagen de julio es la que peores resultados ha dado. Este resultado no sorprende, ya que viendo el calendario agronómico de los cultivos clasificados (**Tabla 1**), se observa que en julio todos los cultivos excepto el girasol se encuentran cosechados, de modo que julio, no será un buen mes para identificar los cultivos. McNairn et al., 2009a, obtuvieron OA similares a estos, de 70% (Kappa = 0.60-0.65) utilizando una única imagen óptica (Landsat o SPOT) adquiridos en julio y agosto para clasificar 5 tipos de cultivos. En el mismo estudio, evaluaron la importancia de la fecha de adquisición de la imagen, y vieron que al utilizar una imagen de principios de temporada, la OA descendía hasta 53.7%.

4.1.2. Resultados utilizando varias escenas radar (Mahalanobis).

El uso de varias imágenes radar (multitemporalidad) así como la fecha en la que se adquieren, son dos aspectos importantes a tener en cuenta si se quieren obtener buenos resultados (Larrañaga et al., 2010). Mangolini y Arino, 1996, comprobaron que

la fiabilidad global de la clasificación de cultivos mejoraba al aumentar el número de imágenes radar (ERS-1) utilizadas, de un 43% al utilizar 8 imágenes a un 56% y 70% al utilizar 9 y 20 imágenes respectivamente.

Estudios más recientes como el de Stankiewicz, 2006 y McNairn et al., 2009b, consiguieron fiabilidades de hasta el 75-80% al combinar 3 escenas radar tomadas con sensores SAR más actuales (de polarización simple o doble) adquiridos entre mayo y julio.

En el presente estudio, se aprecia que los resultados de las imágenes multitemporales van mejorando a medida que se va aumentando el número de imágenes utilizadas, pasando de 43% a 65% y de 0.31 a 0.55 el OA y el coeficiente de Kappa (**Tabla 5**). Además, se aprecia que la imagen de julio no aporta mejoras significativas ya que su inclusión en la clasificación apenas varía el resultado obtenido.

Modelo	Imágenes utilizadas	OA	Kappa
Radar	ERS_ab_my	43%	0.31
Radar	ERS_ab_my_jn	53%	0.41
Radar	ERS_ab_my_jn_jl	55%	0.41
Radar	ERS_ab_my_jn_ENV_jn	65%	0.55
Radar	ERS_ab_my_jn_jl_ENV_jn	66%	0.55

Tabla 5. Fiabilidad global (OA) y coeficiente Kappa de las distintas imágenes radar multitemporales clasificadas con Mahalanobis.

4.1.3. Resultados utilizando la combinación óptico-radar (Mahalanobis).

Una vez comprobado la escasa influencia que tiene la imagen de julio sobre el resultado de la clasificación, se decide prescindir de ella. Por lo tanto, la información radar utilizada en la combinación óptico-radar corresponderá a los datos de ERS-2 (abril, mayo y junio) y Envisat (junio).

Al añadirle esta información radar a la imagen Landsat de mayo, el OA mejora un 6% y el Kappa global un 11%. En el caso de la combinación de Landsat de junio y radar, las precisiones no mejoran tanto, suben un 1% y 4% el OA y Kappa respectivamente (**Tabla 6**).

Modelo	Imágenes utilizadas	OA	Kappa
Óptico + Radar	LS_mayo + ERS_ab_my_jn_ENV_jn	82%	0.75
Óptico + Radar	LS_junio + ERS_ab_my_jn_ENV_jn	81%	0.74

Tabla 6. Fiabilidad global (OA) y coeficiente Kappa de las distintas combinaciones óptico-radar clasificadas con Mahalanobis.

4.2. Resultados a nivel de cultivo

En este último apartado, se van a comparar y analizar en detalle las clasificaciones de las imágenes ópticas y de las combinaciones óptico-radar. La información radar lo componen los datos de ERS-2 (abril, mayo y junio) y Envisat (junio).

Para cada uno de los casos, además de los dos índices globales mencionados anteriormente (OA y Kappa global), se analizarán la fiabilidad del usuario y productor promediada a nivel global y la matriz de confusión, el coeficiente de Kappa y el índice de Hellden por cultivo;

- × La fiabilidad del usuario, indica la fiabilidad de la clasificación, mientras que la fiabilidad del productor indica el porcentaje de la verdad campo que se clasifica bien. Estos dos estadísticos son complementarios y deben de analizarse conjuntamente. El valor promedio que se muestra en las tablas 7 a 10, es la media ponderada teniendo en cuenta las probabilidades a priori de cada cultivo.
- × El índice Hellden corresponde a la media armónica de la fiabilidad del usuario y del productor. Este índice, es una manera sencilla de estudiar esas dos fiabilidades conjuntamente.

4.2.1. Análisis de las matrices de confusión y fiabilidades del usuario y productor.

4.2.1.1. Landsat (mayo) (MLC) vs. Landsat (mayo) + radar (Mahalanobis)

Tal y como se ha visto anteriormente, en el caso de la imagen óptica de mayo, la fiabilidad y Kappa global mejoran un 6% y 11% respectivamente al combinar datos ópticos y radar. La fiabilidad media del usuario y productor, también mejoran un 15% y 4% cada uno (**Tablas 7 y 8**).

Imágenes utilizadas		Algoritmo		Fiabilidad global		Kappa global		Promedio fiab. Productor		Promedio fiab. Usuario	
Landsat (mayo)		MLC		76%		0.64		77%		73%	
		Verdad campo									
		Trigo	Cebada	Avena	Girasol	Guisante	Barbecho con cub.	Barbecho	Habas	Colza	Pastos
Clasificado	Trigo	93%	30%	24%	1%	-	13%	71%	54%	7%	-
	Cebada	5%	65%	4%	1%	77%	79%	10%	46%	-	-
	Avena	3%	4%	71%	-	-	8%	-	-	73%	-
	Girasol	-	-	-	85%	4%	-	13%	-	-	-
	Guisante	-	-	-	-	14%	-	-	-	-	-
	Barbecho con cubierta	-	-	-	-	-	0%	-	-	-	-
	Barbecho	-	-	-	12%	5%	-	5%	-	-	-
	Habas	-	-	-	-	-	-	-	0%	-	-
	Colza	-	-	-	-	-	-	-	-	19%	-
Pastos		-	-	1%	-	-	-	-	-	-	100%
Total		100%	100%	100%	100%	100%	100%	100%	100%	100%	100%

Tabla 7. Matriz de confusión de Landsat de mayo, MLC.

Imágenes utilizadas		Algoritmo	Fiabilidad global		Kappa global		Promedio fiab. Productor		Promedio fiab. Usuario		
LS_mayo + Radar		Mahalanobis	82%		0.75		81%		88%		
		Verdad campo									
		Trigo	Cebada	Avena	Girasol	Guisante	Barbecho con cub.	Barbecho	Habas	Colza	Pastos
Clasificado	Trigo	81%	9%	2%	-	-	-	-	-	-	-
	Cebada	3%	74%	4%	-	-	1%	-	-	-	-
	Avena	3%	1%	89%	-	-	-	-	-	-	-
	Girasol	3%	3%	2%	100%	4%	8%	32%	-	7%	-
	Guisante	5%	7%	3%	-	96%	13%	5%	1%	-	-
	Barbecho con cubierta	-	-	1%	-	-	79%	-	-	-	-
	Barbecho	1%	-	-	-	-	-	66%	-	-	-
	Habas	3%	5%	-	-	-	-	-	99%	-	-
	Colza	-	-	-	-	-	-	-	-	93%	-
Pastos	-	-	-	-	-	-	-	-	-	100%	
Total		100%	100%	100%	100%	100%	100%	100%	100%	100%	100%

Tabla 8. Matriz de confusión de la combinación Landsat (mayo) + radar, Mahalanobis.

Al utilizar únicamente la imagen Landsat de mayo, se observa que los cereales trigo, cebada y avena, se confunden mucho entre ellos debido a que en el mes de mayo, el desarrollo vegetativo de estos cultivos es muy parecido. Por otro lado, el resto de los cultivos excepto el girasol y los pastos, también se confunden con los cereales. Más del 70% de los píxeles de guisante, barbecho (con y sin cubierta), habas y colza se clasifican como cereales (**Tabla 7**).

En cuanto al girasol, mencionar que en Navarra, el grueso de las siembras se realiza a finales del mes de abril y a principios de mayo (fuente: ITG Agrícola). Por lo tanto, hay que interpretar con cuidado los resultados obtenidos para esta clase, dado que en mayo lo más probable es que se haya observado el suelo desnudo y no el cultivo en sí. Por otro lado, volviendo a consultar el calendario agronómico de estos cultivos (**Tabla 1**), también se deduce que mayo no es un buen mes para discriminar el guisante ya que para esa época, este cultivo se encuentra totalmente cosechado. Las

habas y la colza, también se clasifican mal (**Tabla 7**). Esto puede deberse a que se disponía de poca muestra de estos cultivos ya que la fecha en la que se adquiere la imagen óptica es a priori adecuada.

Al añadir la información radar, los resultados mejoran considerablemente. El trigo es el único cultivo que obtiene un resultado algo inferior, 81% frente a 93%. Probablemente, esto se deba a la alta probabilidad a priori asignada al trigo al clasificar la imagen óptica con MLC (Mahalanobis no utiliza esas probabilidades a priori). Los porcentajes de los cultivos bien clasificados han sido del orden de 66 – 100% en todos los casos (**Tabla 8**).

El barbecho, tanto con cubierta como sin cubierta, es un cultivo muy heterogéneo. Cabe pensar que la firma obtenida será poco precisa y en consecuencia, no se clasifica adecuadamente en ninguno de los casos.

4.2.1.2. Landsat (junio) (MLC) vs. Landsat (junio) + radar (Mahalanobis)

En el caso de la imagen óptica de junio, la fiabilidad y Kappa global mejoran menos, un 1 y 4% respectivamente al combinar datos ópticos y radar. La fiabilidad media del productor se mantiene constante, mientras que la del usuario aumenta un 8% (**Tablas 9 y 10**).

Imágenes utilizadas		Algoritmo		Fiabilidad global		Kappa global		Promedio fiab. Productor		Promedio fiab. Usuario	
Landsat (junio)		MLC		80%		0.70		80%		78%	
		Verdad campo									
		Trigo	Cebada	Avena	Girasol	Guisante	Barbecho con cub.	Barbecho	Habas	Colza	Pastos
Clasificado	Trigo	92%	17%	25%	29%	14%	25%	74%	100%	17%	-
	Cebada	2%	80%	8%	-	5%	4%	3%	-	8%	-
	Avena	6%	3%	67%	-	-	-	-	-	-	-
	Girasol	-	-	1%	71%	37%	-	10%	-	-	-
	Guisante	-	-	-	-	0%	-	-	-	-	-
	Barbecho con cubierta	-	-	-	-	-	71%	-	-	-	-
	Barbecho	-	-	-	-	-	-	13%	-	-	-
	Habas	-	-	-	-	-	-	-	0%	-	-
	Colza	-	-	-	-	44%	-	-	-	75%	-
	Pastos	-	-	-	-	-	-	-	-	-	100%
Total		100%	100%	100%	100%	100%	100%	100%	100%	100%	100%

Tabla 9. Matriz de confusión de Landsat de junio, MLC.

Imágenes utilizadas		Algoritmo		Fiabilidad global		Kappa global		Promedio fiab. Productor		Promedio fiab. Usuario	
LS_junio + Radar		Mahalanobis		81%		0.74		80%		86%	
		Verdad campo									
		Trigo	Cebada	Avena	Girasol	Guisante	Barbecho con cub.	Barbecho	Habas	Colza	Pastos
Clasificado	Trigo	73%	5%	1%	-	-	-	-	-	-	-
	Cebada	4%	84%	7%	-	-	-	1%	-	-	-
	Avena	11%	-	86%	-	-	-	-	-	-	-
	Girasol	7%	6%	5%	97%	9%	8%	20%	-	1%	-
	Guisante	4%	5%	2%	3%	86%	3%	-	1%	-	-
	Barbecho con cubierta	-	-	-	-	-	86%	-	-	-	-
	Barbecho	1%	1%	-	-	5%	3%	82%	-	-	-
	Habas	-	-	-	-	-	-	-	99%	-	-
	Colza	-	-	-	-	-	-	-	-	99%	-
	Pastos	-	-	-	-	-	-	-	-	-	100%
Total		100%	100%	100%	100%	100%	100%	100%	100%	100%	100%

Tabla 10. Matriz de confusión de la combinación Landsat (junio) + radar, Mahalanobis.

Con las clasificaciones de Landsat de junio y la combinación de óptico-radar, sucede lo mismo que con las clasificaciones anteriores de mayo. Cuando se utiliza solamente la imagen óptica de junio, **tabla 9**, los cereales se siguen confundiendo entre ellos y excepto el pasto, el resto de cultivos se clasifican principalmente como trigo. Las habas y el guisante se siguen clasificando especialmente mal, probablemente, tal y como se ha comentado anteriormente, debido a la poca muestra disponible en el caso de las habas y a la inadecuada fecha de la imagen óptica para diferenciar el guisante.

En este caso también, al añadir la información radar los resultados mejoran. El trigo vuelve a ser el único cultivo que obtiene un resultado algo inferior, 73% frente a 92%. Los porcentajes de los cultivos bien clasificados han sido del orden de 73 – 100% en todos los casos. Los cultivos minoritarios (girasol, guisante, barbecho, habas y colza) no se confunden con los cereales. En este caso también, el barbecho es el que peores resultados ha obtenido debido a su heterogeneidad (**Tabla 10**).

4.2.2. Análisis del coeficiente de Kappa e índice de Hellden por cultivo.

A continuación, se analizan el coeficiente de Kappa y el índice Hellden de cada cultivo y para cada clasificación.

Los cereales, la colza y los pastos, obtienen coeficientes Kappa > 0.8 al combinar la imagen Landsat de mayo con el radar. Sin embargo, al utilizar una única imagen óptica los coeficientes de Kappa de trigo y avena, no superan el 0.6. Esta mejora que se obtiene con los cereales es considerable y más aún al tratarse de la clase mayoritaria de la zona. El guisante y el girasol, toman valores superiores de Kappa al utilizar una única imagen óptica. No obstante, viendo las fechas en las que se adquieren estas imágenes ópticas, se concluye que lo que se estará clasificando será el suelo desnudo

y habrá que tener especial cuidado a la hora de interpretar estos resultados. El barbecho (con y sin cubierta) debido a su heterogeneidad, sigue dando unos resultados un tanto dispares. Las habas, la colza y los pastos obtienen mejores Kappas cuando se utiliza la combinación óptico-radar (**Figura 2**).




Figura 2. Coeficiente Kappa por cultivo y para cada clasificación.

En cuanto al índice de Hellden, todos los cultivos excepto el girasol, obtienen mejores resultados al utilizar una de las dos combinaciones óptico-radar. Los cultivos que peores resultados dan vuelven a ser el guisante, el barbecho y las habas (**Figura 3**).




Figura 3. Índice de Hellden por cultivo y para cada clasificación.

5. CONCLUSIONES

La fecha en la que se adquieren las imágenes, tanto ópticas como radar, es vital en el resultado de la clasificación debido al distinto estado de desarrollo vegetativo del cultivo. Es importante conocer el ciclo productivo de los cultivos a clasificar y, a ser posible, seleccionar las imágenes en función del mismo.

Las imágenes ópticas, siempre y cuando la fecha de adquisición sea la óptima, son capaces de obtener muy buenos resultados incluso cuando se clasifican individualmente.

El uso de una única imagen radar de simple polarización, no ha demostrado la capacidad de discriminar bien los cultivos y por ende, obtener buenos resultados. No obstante, a medida que se han ido añadiendo imágenes de distintas fechas, los resultados han ido mejorando, llegando a obtener un OA de 65% y Kappa de 0.55 en el mejor de los casos.

La polarización de las imágenes radar utilizada ha sido VV. Quedaría pendiente ver si la polarización HV es capaz de obtener mejores resultados, tal y como han demostrado estudios anteriores (Lee et al., 2001).

Los mejores resultados se han obtenido al combinar las imágenes ópticas con datos radar, llegando a un OA y Kappa de 82% y 0.75 cada uno. Aunque las diferencias entre las fiabilidades globales de las clasificaciones ópticas y óptico-radar no sean muy significativas, sí lo son a nivel de cultivo.

Los algoritmos de clasificación utilizados han sido los más convencionales. Habría que estudiar clasificadores más específicos de clasificación a nivel de objeto y para imágenes multi-temporales, como por ejemplo Random Forests.

REFERENCIAS

Bauer, M.E. and Cipra, J.E., 1973. Identification of agricultural crops by computer processing of ERTS MSS data. *Symposium on significant results obtained from the Earth Resources Technology Satellite-1*. NASA, SP-327, pp. 205-212.

Chuvieco, E., 2002. Teledetección ambiental: La observación de la Tierra desde el Espacio. Editorial Ariel Ciencia. Barcelona.

Cuevas, J.M., Llop, R., González, F. y López S., 1988. Utilización de la información espectral MSS-Landsat 4 en la estimación de superficies ocupadas por cultivos anuales de secano. Aplicación en la provincia de Toledo. *Investigación Agraria: Producción y protección de vegetales*, vol. 3, pp. 329-346.

Larrañaga, A., Albizua, L. and Álvarez-Mozos, J. 2010. Crop classification in central Navarre using polarimetric radar data. *Revista de Teledetección*, en revisión.

Lee, J.S., Grunes, M.R. and Pottier, E. 2001. Quantitative comparison of classification capability: Fully polarimetric versus dual and single-polarization SAR. *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 39, No. 11, pp. 2343-2351.

Mangolini, M. and Arino, O., 1996. ERS-SAR and Landsat-TM multitemporal fusion for crop statistics. *EOQ*, Nr. 51.

McNairn, H., Champagne, C., Shang, J., Holmstrom, D. and Reichert, G. 2009a. Integration of optical and Synthetic Aperture Radar (SAR) imagery for delivering operational annual crop inventories. *ISPRS Journal of Photogrammetry and Remote Sensing*, Vol. 64, No. 5, pp. 434-449.

McNairn, H., Shang, J.L., Jiao, X.F. and Champagne, C. 2009b. The Contribution of ALOS PALSAR Multipolarization and Polarimetric Data to Crop Classification. *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 47, No. 12, pp. 3981-3992.

Pedley, M.I. and Curran P.J., 1991. Per field classification: an example using SPOT HRV imagery. *International Journal of Remote Sensing*, vol. 12, pp. 2181-2192.

Stankiewicz, K.A. 2006. The efficiency of crop recognition on ENVISAT ASAR images in two growing seasons. *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 44, No. 4, pp. 806-814.

Thompson, F.G., 1973. Crop species recognition and mensuration in the Sacramento Valley. *Symposium on significant results obtained from the Earth Resources Technology Satellite-1*. NASA, SP-327, pp. 181-188.

Townsend, J.R.G., 1984. Agricultural land-cover discrimination using Thematic Mapper spectral bands. *International Journal of Remote Sensing*, vol. 5, pp. 681-698.

Backscattering Behavior of Rain-Fed Crops Along the Growing Season

Arantzazu Larrañaga, Jesús Álvarez-Mozos, Lourdes Albizua, and Jan Peters

Abstract—Radar backscatter depends mainly on the characteristics of observed covers and on the configuration of the sensor. In agricultural areas, as crops grow, their characteristics vary, and their backscattering behavior changes. The main objective of this study is to perform a multitemporal analysis of the variations in backscatter coefficients and ratios at different polarizations due to the growth stage of each crop and, in turn, to establish the optimal dates for accurate crop separation and classification. With this aim, five RADARSAT-2 scenes were acquired over the Pamplona basin (North of Spain) between March and June 2010, covering the major part of the growing season of agricultural crops in this area. The results obtained illustrate the importance of May and June acquisitions, particularly in VV and HV polarizations, for obtaining adequate crop separabilities and accurate classification results. Cereals showed a particular behavior with a stronger attenuation in VV polarization than in HH, due to the vertical orientation of stems, during the vegetative growth stages. In early June, barley had a peak in HV polarization, revealing an earlier heading compared to wheat and oats. Rapeseed and peas had a strong volume scattering contribution due to their heterogeneous canopies, and sunflower could be discriminated because of its different agricultural calendar. Crops were classified with an accuracy of 80% using just three RADARSAT-2 scenes acquired between May and June.

Index Terms—Backscatter, C-band, crop monitoring, multi-polarization, multitemporality, radar.

Este artículo ha sido eliminado por restricciones de derechos de autor.

Manuscript received March 6, 2012; revised May 22, 2012; accepted June 18, 2012. Date of publication August 13, 2012; date of current version October 22, 2012. This work was supported in part by the Spanish National Scientific Research, Development and Technological Innovation Plan through Project CGL2011-24336.

A. Larrañaga and L. Albizua are with the Department of Earth Information Systems, Tracasa, 31621 Sarriguren, Spain.

J. Álvarez-Mozos is with the Department of Projects and Rural Engineering, Public University of Navarre, 31006 Pamplona, Spain (e-mail: jesus.alvarez@unavarra.es).

J. Peters is with Flemish Institute for Technological Research (VITO), 2400 Mol, Belgium.

Digital Object Identifier 10.1109/LGRS.2012.2205660



Article

On the Added Value of Quad-Pol Data in a Multi-Temporal Crop Classification Framework Based on RADARSAT-2 Imagery

Arantzazu Larrañaga ^{1,*} and Jesús Álvarez-Mozos ²¹ Department of Territorial Information Systems, Tracasa, Cabárceno 6, 31621 Sarriguren, Spain² Department of Projects and Rural Engineering, Public University of Navarre, Los Tejos, Arrosadia s/n, 31006 Pamplona, Spain; jesus.alvarez@unavarra.es* Correspondence: alarranaga@tracasa.es; Tel.: +34-948-289-000 (ext. 374)

Academic Editors: Anton Vrieling, James Campbell and Prasad S. Thenkabail

Received: 7 December 2015; Accepted: 12 April 2016; Published: 18 April 2016

Abstract: Polarimetric SAR images are a rich data source for crop mapping. However, quad-pol sensors have some limitations due to their complexity, increased data rate, and reduced coverage and revisit time. The main objective of this study was to evaluate the added value of quad-pol data in a multi-temporal crop classification framework based on SAR imagery. With this aim, three RADARSAT-2 scenes were acquired between May and June 2010. Once we analyzed the separability and the descriptive analysis of the features, an object-based supervised classification was performed using the Random Forests classification algorithm. Classification results obtained with dual-pol (VV-VH) data as input were compared to those using quad-pol data in different polarization bases (linear H-V, circular, and linear 45°), and also to configurations where several polarimetric features (Pauli and Cloude–Pottier decomposition features and co-pol coherence and phase difference) were added. Dual-pol data obtained satisfactory results, equal to those obtained with quad-pol data (in H-V basis) in terms of overall accuracy (0.79) and Kappa values (0.69). Quad-pol data in circular and linear 45° bases resulted in lower accuracies. The inclusion of polarimetric features, particularly co-pol coherence and phase difference, resulted in enhanced classification accuracies with an overall accuracy of 0.86 and Kappa of 0.79 in the best case, when all the polarimetric features were added. Improvements were also observed in the identification of some particular crops, but major crops like cereals, rapeseed, and sunflower already achieved a satisfactory accuracy with the VV-VH dual-pol configuration and obtained only minor improvements. Therefore, it can be concluded that C-band VV-VH dual-pol data is almost ready to be used operationally for crop mapping as long as at least three acquisitions in dates reflecting key growth stages representing typical phenology differences of the present crops are available. In the near future, issues regarding the classification of crops with small field sizes and heterogeneous cover (*i.e.*, fallow and grasslands) need to be tackled to make this application fully operational.

Keywords: RADARSAT-2; polarimetric features; separability; Random Forests; crop classification

1. Introduction

Crop classification is one of the major agricultural applications of remote sensing. Knowing the crop present on each agricultural field is a very valuable information at a range of scales. At the local and regional scales this information is a basic requirement to forecast yields and manage crop production [1], but also to design agricultural policies and manage subsidies (e.g., European Common Agricultural Policy (CAP) subsidies) [2]. At the continental and global scales this information is key to ensure food security, but can also impact the market prices of major staple crops, and even affect forecasts on climate dynamics and water and carbon balances [3].

Remote sensing is a rich data source for mapping crops at different scales. Typical approaches based on multispectral imagery rely on the spectral signature of crops [4]. However, this might be of limited use because several crops might have very similar spectral signatures, since these are mostly governed by the presence of pigments and the cellular structure of the mesophyll of leaves. Also, persistent cloud cover imposes serious limits to the viability of optical remote sensing based approaches in some regions of the world [5]. The multi-temporal approach can potentially circumvent these issues. In particular, at continental and global scales, moderate resolution instruments (e.g., MODIS and the alike) with a high revisit frequency have proven successful in identifying major crop types through the analysis of their temporal signature in relation to crop phenology [6]. However, at more detailed scales, the increased spatial resolution comes along with a less frequent revisit and the multi-temporal approach is thus compromised. Some missions, in particular Sentinel-2, can provide a good opportunity to increase the revisit time through the use of large swaths and twin sensors that double the acquisition frequency [7].

Another alternative is the use of Synthetic Aperture Radar (SAR) sensors that operate regardless of solar illumination or cloud cover conditions and provide complementary information to that of optical ones [8]. SAR sensors transmit an electromagnetic pulse at a microwave frequency towards the earth surface and receive the echo reflected or scattered back. After calibration, the backscattering coefficient (σ°) can be obtained, which is a physical property depending on the dielectric and geometric properties of the target and on the configuration of the sensor too. In particular, the frequency (or band) at which the sensor operates, the incidence angle of the incoming radar pulse and the polarization of the transmitted and received waves strongly affect the σ° observed for a certain crop cover [9]. Regarding the frequency, most space-borne SARs operate in C-band (~5 GHz) (e.g., RADARSAT-1 and -2, Sentinel-1 and RISAT-1), but there are some operating in L-band (~1 GHz) (e.g., ALOS/PALSAR-2) and X-band (~10 GHz) (e.g., TerraSAR-X and CosmoSkyMed). At high frequencies (*i.e.*, short wavelengths) the incoming waves have a shallow penetration capacity into the vegetation canopy and only interact with the most superficial elements, whereas at lower frequencies (*i.e.*, longer wavelengths) the penetration depth increases although it depends on the characteristics of the vegetation. The incidence angle is also a key element affecting the penetration depth of the SAR signal. Small incidence angles (close to nadir observation) lead to higher penetration depths than large ones. Most SARs provide a selectable incidence angle configuration ranging normally between 20° and 50°.

Polarization refers to the orientation of the electric field of the radiation pulse, and in most cases this can be vertical (V) or horizontal (H). Accordingly, SAR observations can be co-polarized (*i.e.*, transmitted and received in the same polarization: VV or HH) or cross-polarized (*i.e.*, transmitted in one polarization and received in the other: VH or HV). Distributed targets (*i.e.*, natural land covers) normally show reflection symmetry, and thus cross-polarized channels HV and VH can be assumed to provide the same information. The first SARs launched in the 1990s (ERS-1 and -2, JERS-1, and RADARSAT-1) were single polarization sensors, and thus imaged the Earth surface on a single co-polarized channel (HH or VV). This seriously limited their ability for crop mapping [10]. However, next generation SARs (e.g., ENVISAT/ASAR, RADARSAT-2, ALOS/PALSAR-1, TerraSAR-X, and the recently launched satellites Sentinel-1 and ALOS/PALSAR-2) provide a multi-polarization capacity that makes them better suited for crop classification applications [11]. Some of these operate in dual-pol configurations (normally VV-VH or HH-HV) and some in quad-pol configuration (*i.e.*, VV-VH-HV-HH). The latter provide a full description of the scattering phenomena through the use of polarimetric analysis techniques. These techniques exploit the information contained in the 4×4 scattering matrix, whose entries are complex elements describing both the amplitude and the phase of the scattered pulse [9]. Polarimetry offers a range of analysis techniques that enable the representation of the scattering signature of a target, the representation of scattering in different polarization bases, the computation of polarimetric features that enhance a particular property of targets, or the decomposition of the polarimetric information in some features that relate to canonical scattering mechanisms [12].

Backscattering coefficients (σ°) at different polarization bases can be calculated using polarization synthesis. This technique enables computing the response of the target to any combination of incident and received polarization, which might uncover differences in targets otherwise hidden [13,14]. Another interesting polarimetric feature is the linear co-pol coherence, computed as the complex correlation coefficient between HH and VV polarization channels. Its magnitude ($|\rho_{HH-VV}|$), varies between 0 and 1, and can be helpful to understand target scattering mechanisms, *i.e.*, surface scattering leads to coherence values close to 1, whereas volume scattering close to 0 [15]. The phase of ρ_{HH-VV} is equal to the phase difference between HH and VV channels (ϕ_{HH-VV}), which is a characteristic of the number of bounces taking place in the reflection. An ideal smooth dielectric surface (single or odd-bounce) would have a ϕ_{HH-VV} of 0° , whereas an ideal dihedral (double or even-bounce) would have a ϕ_{HH-VV} of $\pm 180^\circ$. Natural targets, such as agricultural crops, normally have variable values of ϕ_{HH-VV} (from -180° to $+180^\circ$), depending on the characteristics of the target (and the configuration of the sensor). For instance, crops with vertical canopy architectures might lead to differences in ϕ_{HH-VV} when compared to other crops [16,17].

Polarimetric decompositions resume the full polarimetric information into few features that can be interpreted in terms of the main scattering mechanisms occurring at each target, and hence its bio-geophysical characteristics [18]. The Pauli decomposition expresses the scattering matrix as a function of three components that represent, namely surface scattering ($|S_{HH} + S_{VV}|$), volume scattering ($|S_{HV}|$) and double-bounce ($|S_{HH} - S_{VV}|$). These three components can be arranged in informative RGB color-composites that can be easily interpreted in terms of the main scattering mechanisms. Alternatively, the Cloude–Pottier decomposition [18] is based on the eigen-decomposition of the polarimetric coherency matrix and yields three features: entropy (H), alpha angle (α), and anisotropy (A). Entropy measures the degree of disorder or mixture of different scattering mechanisms on a target, with 0 = one single scattering mechanisms and 1 = several mixed scattering mechanisms. Alpha angle represents the scattering mechanism, with 0° corresponding to surface scattering, 90° to double bounce and intermediate values around 45° to volume scattering. The average alpha angle (α) represents the average scattering mechanism on a target, whereas the dominant alpha angle (α_1) indicates the scattering mechanism that is predominant on a target. The latter is more informative in targets with high entropy (no single dominant scattering mechanism) [19]. Finally, anisotropy represents the relative importance of the secondary and tertiary scattering mechanisms, and thus should be evaluated only when more than one scattering mechanism exists (*i.e.*, $H > 0.7$) [12].

All this information can be useful to describe the physical properties of the targets being imaged and even to perform non-supervised classifications [20,21]. However, quad-pol sensors have limitations due to their complexity, their increased data rate and reduced coverage and revisit time. For instance, RADARSAT-2 dual-pol Standard Beam Mode images have a nominal swath of 100 km, whereas Standard Quad Polarization Beam Mode images have a nominal swath of only 25 km. Therefore, it is necessary to assess the added value of quad-pol observations with regard to different applications, and in particular to crop classification.

Previous studies have shown that quad-pol data can successfully classify major crop types [22,23] and even monitor crop phenology [24,25] or detect crop lodging [26]. A basic requirement for this is that scenes should be acquired on dates when crops show differences apparent to the sensor, that is, they behave differently when the electromagnetic pulse impinges on them. Different crops may have different planting and harvest dates and also phenology can evolve differently. In this sense, previous studies [11,25,27–30] stressed the importance of multi-temporal data for an adequate crop identification. Classifications done using as input several SAR scenes acquired in key dates of the crop cycle can yield accurate results [11,13,31]. However, it is still necessary to know whether quad-pol data could add or not significant information on a classification framework based on multi-temporal SAR imagery. Therefore, the objective of this study is to evaluate the added value of quad-pol data in a multi-temporal crop classification framework based on SAR imagery.

In [30], five RADARSAT-2 scenes acquired between March and July 2010 were used to investigate the optimal dates for crop identification. Using as input just three scenes acquired between May and June (each with quad-pol backscatter coefficients and their ratios), overall classification accuracies of 82% were obtained, successfully discriminating most crops. In this study, we started from the same three scene configuration. Then, the analysis was extended investigating whether comparable results were obtained using just dual-pol data. Finally, we evaluated whether quad-pol data represented in other polarization bases or the inclusion of different polarimetric features lead to enhanced classification results.

2. Study Site and Dataset

The study site corresponds to the agricultural areas surrounding the city of Pamplona (Figure 1), in central Navarre (North of Spain). The region has a rolling topography with cultivated areas normally located in plains and areas of gentle slopes (below 5%), and grasslands and forests occupying steeper areas. Field sizes are variable, but most fields range between 1 and 3 ha.

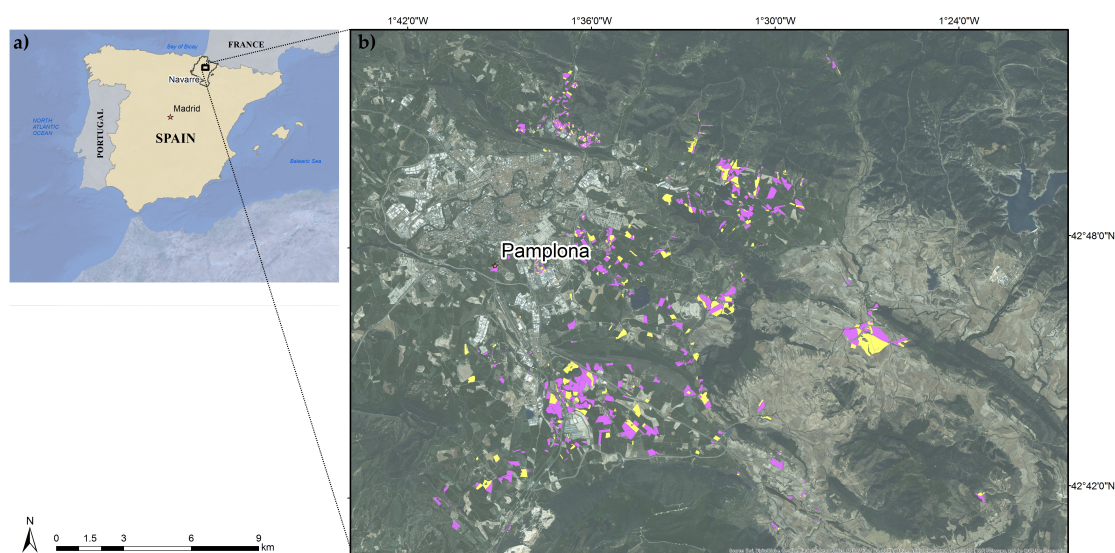


Figure 1. Location of the study area in Navarre, Spain (a) and ground truth data used over an optical image (b). Training and test set areas are presented in purple and yellow, respectively.

In this region, an area of 25 km \times 25 km was selected, where rain-fed agriculture is the main land use. In particular, winter cereals are the most frequent crops. In the year studied, wheat represented 55% of the total cultivated area, whereas barley and oats accounted for 16% and 15%, respectively. Other crop types, found in much lower abundance, were sunflower, rapeseed, peas, vetch, permanent grasslands, and fallow. Photographs of the crops studied are given in Figure 2.

The agricultural calendar in this area is typical of rain-fed winter crops. Crops are normally sown in October and harvested in the beginning of July (Figure 3), with the exception of sunflower (planted in April and harvested in September). Although phenological stages develop very similarly in the three cereal crops (barley, wheat, and oats), barley plants flower and mature earlier. Barley stems are weaker than those of wheat and, as a result, after heading barley plants normally bend and their ears are inclined. On the contrary, wheat plants remain erected with vertical ears until harvest. Oat's phenological events mimic wheat, but its inflorescences are different (*i.e.*, panicles instead of ears). Rapeseed is sown earlier (in September) and flowers in April. In its vegetative phase rapeseed grows vigorously and develops a dense, bush-like canopy that can reach a height of 1–1.5 m. During May rapeseed fruits (pods) develop and then start to ripen. Afterwards, senescence starts and ends at the end of June when plants die and pods are completely dry and hard. Peas and vetch are legume crops

grown as forage in this area. Their calendar is also typical of winter crops, although their sowing date is usually later (end of October or November). They are shorter than cereal plants and their canopies have a dense random structure. After flowering they develop pods that ripen and get dry and hard. Pea pods are longer and thicker than vetch's. Sunflower is the most different crop in terms of calendar and canopy configuration. Sunflower is a broadleaved plant with thick and long stems (compared to the other crops of this study), which is planted in April. Plants usually have a separation of 20–30 cm between each other and after a short and quick vegetative phase they develop large circular flowers that fill in with seeds. Flowers dry and senescence occurs during summer; the crop is finally harvested in September.



Figure 2. Photographs of the different crops studied: (a) wheat; (b) barley; (c) oats; (d) sunflower; (e) rapeseed; (f) peas; (g) vetch; (h) grasslands; and (i) fallow.

Grasslands in this area are mostly permanent covers with no sowing and harvest dates. Instead they are cut (some of them grazed) several times during the season (normally three times), and experience different phenological events depending on their species composition. This cover is therefore very heterogeneous and diverse in terms of management. Finally, fallow fields are normally present for a one-year duration in a rotation cycle of approximately five years. Fallow fields are also quite heterogeneous depending on the techniques used for weed management (e.g., mechanical, chemical, *etc.*).

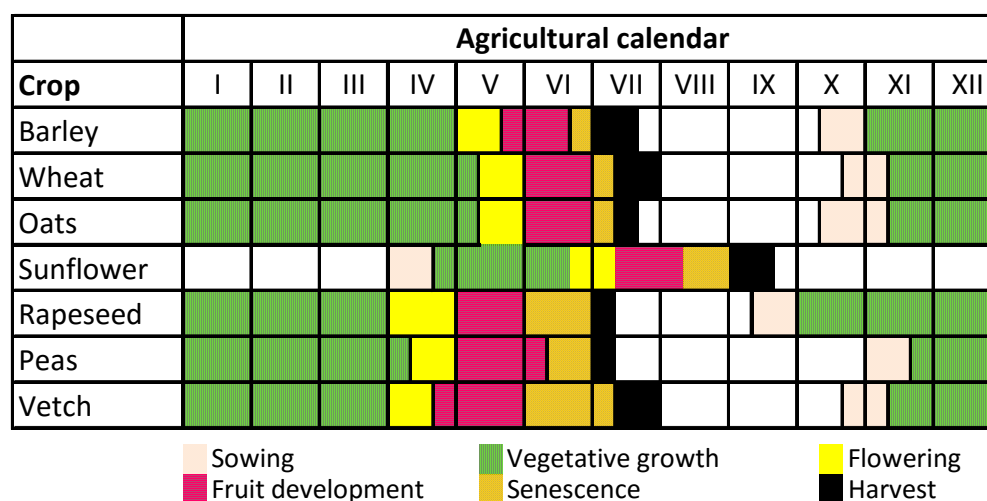


Figure 3. Agricultural calendar of the crops cultivated in the area. Sowing and harvest dates are shown, as well as main phenological stages (their duration is approximate).

During the year 2010, a series of RADARSAT-2 scenes were acquired over the area. Based on a previous analysis [30], the following three acquisition dates were selected: 12 May, 5 June, and 29 June, since they represented optimal dates for accurate crop separation and classification, and in fact, including earlier acquisition dates did not result in higher accuracies [30]. All scenes were acquired in Fine Quad-Pol mode and as Single-Look-Complex products with a spatial resolution of 5.4 m in range and 8.0 m in azimuth. In all cases, the average incidence angle was around 30°.

The ancillary data used consisted of a digital elevation model (DEM) of 5 m, a vector file with field boundaries, and ground truth data resulting from the inspections of the EU CAP program (information not publicly available). The EU CAP program provides subsidies to European farmers depending on the crops being cultivated on each field and the management techniques used. Local administrations are required to inspect a sample of these CAP declarations, so as to verify that farmer declarations conform to reality (*i.e.*, the crops declared by farmers are actually grown on each field). In this particular case, the Government of Navarre inspected a 5% sample of fields selected at random. The total area of the fields inspected within the studied area was above 1600 ha. With this information, a database of 928 fields with known crop class was generated. The number of fields per class varied proportionally to the area covered by each crop in the region. Accordingly, the database had the following number of fields per class: Wheat, 476; Barley, 168; Oats, 165; Sunflower, 24; Rapeseed, 10; Peas, 8; Vetch, 26; Grassland, 17; and Fallow, 34. One portion (2/3) of this information was used as ground truth to build the crop signatures (622 fields), and the rest for accuracy assessment (306 fields); both sets were obtained at random, keeping the same training/test proportions for each class. It should also be taken into account that field size varied strongly with average field size being the largest for fields corresponding to sunflower and rapeseed (>3 ha), followed by grasslands (~2 ha), cereals and fallow (1–2 ha), and lastly peas and vetch (<1 ha).

3. Methodology

Figure 4 shows the general work-flow of this study. In the following subsections different tasks are explained in detail.

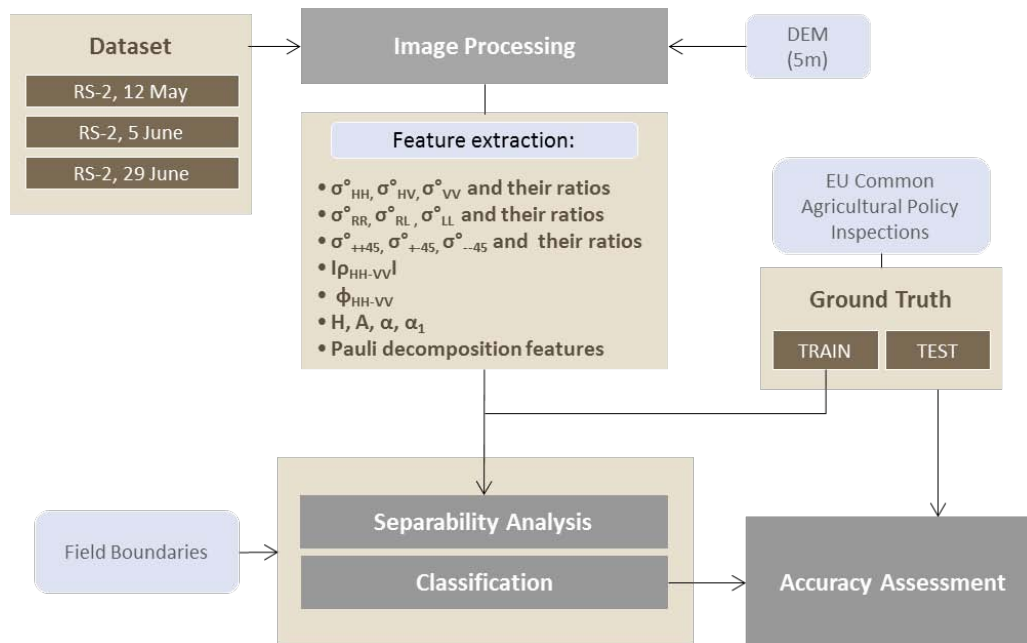


Figure 4. Work-flow chart of the methodology.

3.1. Image Processing

Image processing consisted of the following steps: (1) slant range to ground range conversion; (2) orthorectification; (3) calibration; and (4) speckle filtering. Orthorectification was carried out using a rigorous sensor model that required no ground control points and provided location accuracies below 1 pixel. Image calibration was performed using local incidence angle values computed from the DEM available, to correct radiometric effects of topography. A 3×3 window Gamma-MAP filter was used for speckle reduction. This adaptive filter is effective for reducing speckle while preserving linear characteristics and discrete scatterers [32]. The resulting processed images were resampled to a pixel size of 5 m. Finally, field medians were computed excluding border pixels by applying a 1-pixel buffer to the field boundary vector file. Image processing was performed using Geomatica 10.3, NEST-5.1 and PolSARpro 5.0.

In addition, different polarimetric features were calculated. Backscattering coefficients (σ°) at different polarization bases were calculated using polarization synthesis. In particular, circular and 45° linear polarization bases were used. The first consists of right-handed and left-handed polarization states, leading to two co-polarized (RR and LL) and two cross-polarized (RL and LR) channels. And the second consists of $+45^{\circ}$ and -45° polarization states, leading to two co-polarized ($++$, $--$) and two cross-polarized ($+-$, $-+$) polarization channels. As already explained, for each polarization basis only one cross-polarized channel was used since agricultural fields can be assumed to be reciprocal targets and provide the same information in both cross-polarized channels. Next, backscatter ratios were calculated for the three polarization bases. The polarimetric features considered were, the magnitude ($|\rho_{HH-VV}|$) and phase (ϕ_{HH-VV}) of linear co-pol coherence, the Pauli decomposition components surface scattering ($|S_{HH} + S_{VV}|$), volume scattering ($|S_{HV}|$) and double-bounce ($|S_{HH} - S_{VV}|$) and the Cloude-Pottier decomposition components entropy (H), average alpha angle (α), dominant alpha angle (α_1) and anisotropy (A). Accurate estimation of H/A/alpha and co-pol coherence parameters requires spatial averaging, thus a 5×5 window was considered for alpha and co-pol coherence, and a 9×9 for H and A that are more affected by speckle noise [33]. This averaging limits the utility of these polarimetric features for small fields.

3.2. Separability Analysis

Separability or statistical dissimilarity is a measure of difference between two targets (e.g., agricultural crops) as observed on a particular channel or feature. Different separability measures exist and their underlying assumptions and interpretation differ. Backscatter coefficients and polarimetric features do not necessarily follow Gaussian probability distribution functions (pdfs). Therefore, separability measures not restricted to Gaussian pdfs need to be used to analyze SAR data. With this aim, the Jeffries–Matusita (JM) distance was used (Equation (1)), as it does not make previous assumptions about observations' pdfs [34]. In this work, separability analysis consisted of the evaluation of the JM distance between pairs of crops for different features and dates.

$$J_{ij} = \left\{ \int \left[\sqrt{p(x|\omega_i)} - \sqrt{p(x|\omega_j)} \right]^2 dx \right\} \quad (1)$$

where, J_{ij} is the JM distance between a pair of classes ω_i and ω_j , x refers to the observed feature (e.g., backscatter coefficient or polarimetric feature), and $p(x|\omega_i)$ and $p(x|\omega_j)$ are the conditional probability density functions for x given ω_i and ω_j , respectively.

The JM distance ranges from 0 to 2, with $J_{ij} = 0$ representing two classes that completely overlap, and $J_{ij} = 2$ two classes that are completely separable. Values below 1 represent poor separability, 1–1.5 corresponds to intermediate separability, and 1.5–2 corresponds to high separability [35].

3.3. Classification Algorithm

This study used the Random Forests (RF) classification algorithm [36] to classify different crop types based on RADARSAT-2 derived features. RF is a nonparametric supervised classification scheme with no *a priori* assumptions on the input data sets' pdfs. RF is an ensemble learning technique that generates many decision trees that are aggregated to classify. Tree diversity is guaranteed because trees are trained using different subsets and use different split rules at their nodes. In particular, each tree within the ensemble is trained on a random subset of the original data, resampling the data with replacement. Then, tree nodes are split using the best split variable among a subset of randomly selected predictive variables. As a result, different classification results are obtained from each tree, and a simple majority vote is used to create the final classification result. The RF technique has been applied to a wide variety of disciplines, and in the last decade it has been used with success in remote sensing applications including SAR classification studies [14,37,38].

In this work different RF classifications were performed using the package “randomForest” run on the free software for statistical computing R. The number of trees (“*ntree*”) was optimized and set to 200. The number of input variables considered for the random selection of the best splitting variable at each node (“*mtry*”) was taken as the square root of the total number of input variables considered for each classification. Similar to most classifiers, RF produces weak results when learning from heavily imbalanced training datasets, favoring the majority classes and resulting in a poor prediction of the minority classes [38]. To avoid this behavior different strategies can be followed, such as down-sampling the majority classes or over-sampling the minority classes so that they obtain the same training sample size as the majority ones [39]. In this work the latter option was implemented, but as in [40], rather than simply replicating the minority training sites, synthetically generated training sets were created by randomly perturbing each training site at around one standard deviation of the feature space. This way synthetic training sets statistically equal to the original ones were obtained with a size equal to that of the most frequent class (*i.e.*, wheat).

Different RF classification models were constructed using the same training set but different input features (described in Section 3.1). Results were compared with an independent test set to quantitatively assess classification performance. For this aim, standard accuracy assessment metrics were calculated, *i.e.*, overall accuracy (OA), Kappa coefficient, producer's (PA), and user's accuracies (UA).

4. Results

4.1. Descriptive Analysis

As a preliminary step to the separability analysis and classification, a descriptive analysis of crops' behavior was made for the different features and dates. Figure 5 shows scatterplots of the most significant results that were obtained.

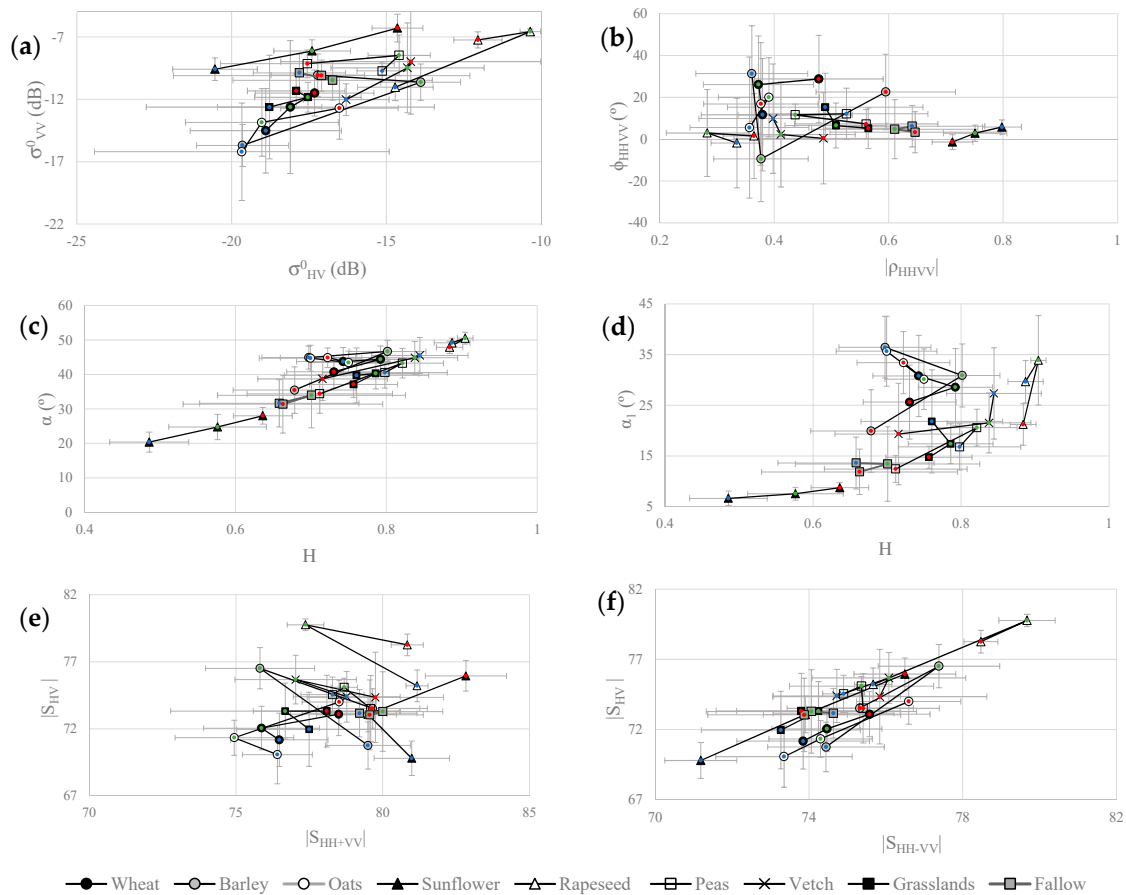


Figure 5. Different scatterplots for the three studied dates: (a) σ_{HV}° vs. σ_{VV}° ; (b) $|\rho_{HHVV}|$ vs. ϕ_{HHVV} ; (c) H vs. α ; (d) H vs. α_1 ; (e) $|S_{HH+VV}|$ vs. $|S_{HV}|$; (f) $|S_{HH-VV}|$ vs. $|S_{HV}|$. Colors represent different dates, blue = 12 May 2010, green = 5 June 2010 and red = 19 June 2010. Points represent class means and error bars ± 1 standard deviation.

Rapeseed produced a significant volume scattering contribution and this can be clearly seen in its high σ_{HV}° value, its alpha value around 45° , and its high $|S_{HV}|$ component, especially for the 5 June scene; similar results for rapeseed were obtained in [41]. The heterogeneous structure of the rapeseed canopy caused a strong depolarization of waves and for this reason the value of H was the highest and the $|\rho_{HH-VV}|$ the lowest.

Due to the late sowing date of sunflower, at the time of image acquisition this crop was in its vegetative phase, with rather small plants (20–50 cm high) that did not completely cover the soil. As a result, its main scattering mechanism was surface scattering, illustrated by a high $|\rho_{HH-VV}|$ and a ϕ_{HH-VV} close to 0° with a very low dispersion (much lower than that of the other crops). This was also confirmed by the lowest values of H and alpha angle, identifying surface scattering as the dominant mechanism. As sunflower plants grew, $|\rho_{HH-VV}|$ decreased and H increased, illustrating a transition to other scattering mechanisms (volume and double bounce).

Generally, dominant alpha (α_1) took lower values than the average alpha (α) but both angles were quite similar if different crops were compared. Sunflower and fallow fields took the lowest values (*i.e.*, surface scattering) and rapeseed and oats the highest, with values close to 45° (*i.e.*, volume scattering).

H values were quite high for all crops except for sunflower (as mentioned above), with values above 0.7 for most crops and dates. After rapeseed (already discussed), peas and vetch had the highest H values; these are crops with a short, bush-like canopy structure. Cereals had slightly lower H values, although barley had a distinctive peak in H on 5 June, likely corresponding to barley ears filling. As ears fill in, barley plants lose their vertical structure and bend at random angles before the plants ripen, which actually takes place earlier than in other cereal crops. This effect is also visible in other polarimetric features. For instance, $|\rho_{HH-VV}|$ had quite a high value in barley for the 29 June scene, probably indicating that harvesting had already taken place. Again, this was confirmed by the decrease in H and alpha angle.

For most of the crops, the increase of Pauli surface scattering ($|S_{HH+VV}|$) on 29 June was clearly apparent. At this time, most winter crops were senescent or even harvested, so electromagnetic radiation could penetrate further in the canopies, leading to an increased surface contribution.

Overall, rapeseed and sunflower were the crops with the largest dynamic range over the time period studied. In contrast, grasslands and fallow remained mostly constant for any of the features studied without showing any clear pattern. These classes showed a very high variability (see error bars in Figure 5), which could probably be a consequence of great differences in management (grassland cutting and weed control in fallow lands) and phenology of these covers.

4.2. Separability Analysis

JM distance was computed to evaluate the separability between each pair of crops for each feature and date. Then, average distance values for each crop with the rest were computed for each date, as well as the average separability of all crop pairs for each feature. It can be observed that JM distance values obtained have a clear temporal variability (Tables 1–5).

Table 1. Average JM distance for each crop and date, as well as the average of all crop pairs, for σ_{HH}° , σ_{HV}° , σ_{VV}° , and their ratios. Colors represent values above 1.00 (blue) and above 1.50 (green), and shades represent the different dates evaluated.

	Wheat	Barley	Oats	Sunflower	Rapeseed	Peas	Vetch	Grassland	Fallow	Average
σ_{HH}°	0.24	0.20	0.33	0.25	0.58	0.35	0.22	0.46	0.36	0.33
	0.52	0.59	0.50	0.66	1.57	0.52	0.39	0.62	0.41	0.64
	0.31	0.34	0.30	0.92	0.85	0.36	0.40	0.77	0.55	0.53
σ_{HV}°	0.49	0.66	0.59	0.87	1.16	1.23	0.70	0.51	0.50	0.75
	0.73	1.01	0.91	0.81	1.90	1.03	0.67	0.62	0.56	0.92
	0.47	0.53	0.43	1.00	1.59	0.44	0.45	0.50	0.42	0.65
σ_{VV}°	0.84	1.16	1.07	1.03	0.86	1.07	0.78	0.61	0.79	0.91
	0.83	0.68	1.11	1.12	1.75	0.80	0.56	0.82	0.62	0.92
	0.64	0.46	0.89	1.27	1.26	0.58	0.43	0.63	0.59	0.75
$\sigma_{HH}^\circ / \sigma_{VV}^\circ$	0.72	1.11	0.92	1.36	0.76	0.76	0.57	0.53	0.58	0.81
	0.58	0.69	0.77	0.83	0.96	0.91	0.45	0.46	0.49	0.68
	0.72	0.60	1.08	0.72	0.69	0.54	0.63	0.54	0.56	0.68
$\sigma_{HV}^\circ / \sigma_{HH}^\circ$	0.40	0.66	0.41	0.95	1.01	0.89	0.48	0.46	0.45	0.63
	0.44	0.48	0.55	1.01	1.42	0.75	0.38	0.41	0.39	0.65
	0.34	0.42	0.32	0.65	1.55	0.42	0.34	0.74	0.31	0.57
$\sigma_{VH}^\circ / \sigma_{VV}^\circ$	0.47	0.54	0.57	1.76	0.85	0.83	0.45	0.48	0.82	0.75
	0.41	0.75	0.43	1.47	1.12	0.82	0.48	0.49	0.50	0.72
	0.37	0.35	0.69	0.99	0.95	0.55	0.37	0.75	0.41	0.60
			12 May		5 June		29 June			

Table 2. Average JM distance for each studied crop and date as well as the average of all crop pairs, for σ°_{RR} , σ°_{RL} , σ°_{LL} , and their ratios. Colors and shades as in Table 1.

	Wheat	Barley	Oats	Sunflower	Rapeseed	Peas	Vetch	Grassland	Fallow	Average
σ°_{RR}	0.37	0.51	0.46	0.91	1.01	0.88	0.59	0.55	0.39	0.63
	0.55	0.89	0.65	0.74	1.82	0.93	0.48	0.56	0.50	0.79
	0.38	0.45	0.43	0.83	1.65	0.39	0.43	0.63	0.51	0.63
σ°_{RL}	0.58	0.80	0.81	1.07	0.75	0.80	0.46	0.51	0.66	0.72
	0.76	0.67	0.92	1.12	1.47	0.57	0.52	0.76	0.53	0.81
	0.50	0.44	0.56	1.56	1.07	0.62	0.52	0.76	0.58	0.73
σ°_{LL}	0.39	0.51	0.45	0.92	1.10	0.99	0.61	0.58	0.51	0.67
	0.55	0.95	0.64	0.69	1.85	0.92	0.58	0.65	0.61	0.83
	0.41	0.49	0.47	0.89	1.50	0.37	0.49	0.77	0.59	0.67
$\sigma^{\circ}_{RR}/\sigma^{\circ}_{LL}$	0.18	0.20	0.20	0.25	0.33	0.35	0.31	0.16	0.19	0.24
	0.17	0.18	0.21	0.39	0.59	0.18	0.45	0.16	0.25	0.29
	0.17	0.17	0.14	0.47	0.28	0.22	0.39	0.14	0.16	0.24
$\sigma^{\circ}_{RL}/\sigma^{\circ}_{RR}$	0.46	0.60	0.47	1.72	1.06	0.72	0.46	0.47	0.82	0.75
	0.39	0.53	0.39	1.48	1.03	0.63	0.39	0.46	0.49	0.64
	0.40	0.35	0.61	1.04	1.21	0.40	0.48	0.46	0.42	0.60
$\sigma^{\circ}_{RL}/\sigma^{\circ}_{LL}$	0.47	0.55	0.53	1.74	0.95	0.77	0.47	0.48	0.95	0.77
	0.41	0.55	0.40	1.47	1.09	0.57	0.49	0.47	0.56	0.67
	0.37	0.40	0.61	1.15	1.09	0.36	0.46	0.74	0.47	0.63
12 May				5 June		29 June				

Table 3. Average JM distance for each studied crop and date as well as the average of all crop pairs, for σ°_{++} , σ°_{+-} , σ°_{--} , and their ratios. Colors and shades as in Table 1.

	Wheat	Barley	Oats	Sunflower	Rapeseed	Peas	Vetch	Grassland	Fallow	Average
σ°_{++}	0.56	0.74	0.73	0.63	0.54	0.54	0.45	0.49	0.51	0.58
	0.81	0.56	0.90	0.92	1.46	0.49	0.57	0.78	0.64	0.79
	0.53	0.46	0.52	1.38	1.16	0.62	0.52	0.73	0.57	0.72
σ°_{R+-}	0.31	0.46	0.33	0.94	1.06	0.49	0.54	0.55	0.38	0.56
	0.48	0.81	0.56	0.74	1.81	0.79	0.58	0.67	0.60	0.78
	0.35	0.39	0.39	0.65	1.45	0.43	0.47	0.76	0.63	0.61
σ°_{--}	0.49	0.77	0.73	0.91	0.64	0.58	0.34	0.47	0.52	0.61
	0.79	0.58	0.97	0.96	1.57	0.75	0.50	0.72	0.51	0.82
	0.56	0.50	0.57	1.43	1.30	0.67	0.47	0.86	0.51	0.76
$\sigma^{\circ}_{++}/\sigma^{\circ}_{--}$	0.22	0.24	0.22	0.59	0.36	0.46	0.42	0.22	0.24	0.33
	0.17	0.23	0.19	0.70	0.17	0.19	0.28	0.40	0.16	0.28
	0.23	0.19	0.35	0.58	0.28	0.40	0.38	0.41	0.20	0.33
$\sigma^{\circ}_{+-}/\sigma^{\circ}_{++}$	0.55	0.70	0.63	1.60	1.05	1.06	0.51	0.49	0.77	0.82
	0.47	0.38	0.53	1.47	0.65	0.47	0.38	0.49	0.49	0.59
	0.47	0.36	0.66	1.24	0.92	0.56	0.35	0.45	0.54	0.62
$\sigma^{\circ}_{+-}/\sigma^{\circ}_{--}$	0.43	0.71	0.53	1.48	0.87	0.42	0.41	0.40	0.71	0.66
	0.48	0.39	0.51	1.48	0.87	0.45	0.38	0.54	0.51	0.62
	0.44	0.35	0.66	1.21	1.04	0.39	0.38	0.49	0.51	0.61
12 May				5 June		29 June				

Table 4. Average JM distance for each studied crop and date as well as the average of all crop pairs, for the Cloude–Pottier features H-A- α and α_1 . Colors and shades as in Table 1.

	Wheat	Barley	Oats	Sunflower	Rapeseed	Peas	Vetch	Grassland	Fallow	Average
α	0.56	0.62	0.58	1.81	1.21	0.63	0.56	0.57	0.98	0.83
	0.51	0.61	0.56	1.74	1.22	0.50	0.48	0.62	0.76	0.78
	0.55	0.45	0.94	1.26	1.34	0.52	0.44	0.64	0.58	0.75
A	0.20	0.17	0.17	0.22	0.60	0.15	0.34	0.32	0.17	0.26
	0.23	0.16	0.25	0.40	0.52	0.15	0.23	0.25	0.14	0.26
	0.19	0.19	0.18	0.42	0.28	0.30	0.26	0.19	0.14	0.24
H	0.59	0.68	0.63	1.68	1.38	0.56	0.79	0.48	0.61	0.82
	0.53	0.52	0.62	1.54	1.58	0.54	0.58	0.50	0.65	0.78
	0.39	0.36	0.38	0.80	1.63	0.32	0.31	0.48	0.43	0.57
α_1	0.60	0.89	0.81	1.69	0.83	1.00	0.53	0.54	1.06	0.88
	0.56	0.73	0.71	1.73	0.76	0.75	0.53	0.83	0.79	0.82
	0.75	0.55	1.27	1.46	0.83	0.88	0.57	0.94	0.74	0.89
12 May				5 June		29 June				

Table 5. Average JM distance for each studied crop and date as well as the average of all crop pairs, for Pauli decomposition features ($|S_{HH} - S_{VV}|$, $|S_{HV}|$, and $|S_{HH} + S_{VV}|$), $|\rho_{HH-VV}|$, and ϕ_{HH-VV} . Colors and shades as in Table 1.

	Wheat	Barley	Oats	Sunflower	Rapeseed	Peas	Vetch	Grassland	Fallow	Average
$ S_{HH} - S_{VV} $	0.52	0.54	0.68	0.88	0.86	1.02	0.40	0.52	0.72	0.68
	0.68	0.47	0.85	0.80	1.32	0.58	0.37	0.44	0.38	0.66
	0.36	0.24	0.46	0.99	0.86	0.25	0.25	0.38	0.24	0.45
$ S_{HV} $	0.40	0.50	0.54	0.83	0.89	0.69	0.52	0.32	0.39	0.56
	0.73	0.91	0.97	0.68	1.82	1.02	0.68	0.53	0.54	0.88
	0.42	0.41	0.34	0.68	1.39	0.29	0.32	0.30	0.32	0.50
$ S_{HH} + S_{VV} $	0.32	0.33	0.36	1.20	0.92	0.73	0.34	0.37	0.34	0.55
	0.42	0.66	0.45	0.58	1.55	0.33	0.36	0.37	0.40	0.57
	0.29	0.34	0.36	0.36	1.30	0.26	0.30	0.45	0.42	0.45
$ \rho_{HH-VV} $	0.49	0.53	0.52	1.70	0.86	0.51	0.44	0.45	0.85	0.71
	0.46	0.49	0.46	1.66	0.85	0.42	0.39	0.60	0.71	0.67
	0.41	0.42	0.71	1.27	1.02	0.37	0.37	0.58	0.50	0.63
ϕ_{HH-VV}	0.26	0.45	0.34	0.89	0.31	0.30	0.26	0.26	0.38	0.38
	0.49	0.46	0.38	0.80	0.29	0.67	0.33	0.31	0.27	0.44
	0.55	0.44	0.42	0.88	0.33	0.49	0.35	0.35	0.36	0.46

12 May

5 June

29 June

Average JM distances were low (<1.0) in most cases. This was somewhat expected, due to the averaging and the similarities existing between many of the crops studied, in terms of their agricultural calendar and morphology (see Section 2). However, sunflower and rapeseed showed a separability >1.0 (and even >1.5 in some cases) with the rest for certain dates and features. Average JM distance values for cereals (*i.e.*, wheat, barley, and oats) were normally low due to their mostly similar behavior during the growing season. In particular, wheat had a separability <1 in all the linear backscatter coefficients and their ratios. Barley had three separability peaks above 1.0, one on 12 May in σ_{VV}° , a second one on 5 June in σ_{HV}° , and a third on 12 May in $\sigma_{HH}^\circ/\sigma_{VV}^\circ$. The first and third correspond to the moment where the flag leaf was deployed, whereas the second could be related to the influence of barley ears. In turn, oats had a separability >1.0 in σ_{VV}° on the first two dates and in $\sigma_{HH}^\circ/\sigma_{VV}^\circ$ on the last (Table 1). This results were mostly in coincidence with [35].

The average JM distance of peas was quite good (>1.0) for σ_{HV}° and σ_{VV}° , obtaining better results on 12 May and 5 June, corresponding with the phase of fruit (pod) development. In general, backscatter ratios did not result in significantly higher separability values than backscatter coefficients. Grasslands, fallow, and vetch were the crops with the lowest separabilities in all the features and dates studied.

Different polarization bases did not appear to provide significant improvements in the outcome of separability (Tables 2 and 3). In general, sunflower and rapeseed had high JM distances (>1.0 and even >1.5 in some cases) with other crops in circular and $+45^\circ-45^\circ$ bases. On the contrary, for cereals, neither cases obtained higher separabilities than those obtained with linear (H-V) basis. As in the previous case, backscatter ratios did not seem to provide enhanced separabilities, with the exception of sunflower, which was best separated on 12 May in both the circular and $+45^\circ-45^\circ$ cross-pol ratios (1.74 and 1.60, respectively). Furthermore, a very low separation (<0.6) was observed for all crops in the circular and $+45^\circ-45^\circ$ co-pol ratios.

JM distances obtained for H-A- α Cloude–Pottier decomposition parameters were variable (Table 4). The highest distance values were obtained by α_1 , followed by α . Therefore, it seems that for this type of target (crops) α_1 is more informative than α . However, there were some exceptions, like sunflower, which showed the highest JM distances with α , although closely followed by H and α_1 on 12 May and 5 June. Also, H and α obtained the highest separabilities for rapeseed, particularly on 29 June. For cereals, JM distances were, in general, low because of their similar characteristics, already mentioned above. However, oats had quite a high JM distance for α_1 on 29 June (and slightly lower for α), this represented the highest separability for this crop in all the features studied. This is due to higher α_1 values for oats ($\sim 33^\circ$) compared to wheat ($\sim 26^\circ$) and barley ($\sim 20^\circ$) (see Figure 5) in the

last part of the season, demonstrating that oats ripen slower and keep a certain volume scattering component, whereas wheat and barley move faster to a surface scattering behavior.

Peas and vetch showed low separability values with the only exception of α_1 on 12 May for peas (Table 4), coinciding with the phenological stage of pod development. It must be taken into account that peas and vetch had the smallest field sizes and this might seriously compromise the accuracy of these polarimetric features due to the spatial averaging required for their calculation. On the contrary, the larger field sizes of sunflower and rapeseed might also favor the ability of H and α to separate them. Finally, anisotropy yielded very low separability distances for all crops, indicating no predominance of a second scattering mechanism (*i.e.*, the second and third scattering mechanisms were at the same level).

Finally, Pauli decomposition parameters, co-pol coherence and phase difference were assessed (Table 5). In this case, and in agreement with the results showed above, sunflower and rapeseed yielded the highest distance values. Sunflower had its highest separabilities in $|\rho_{HH-VV}|$, particularly on 12 May and 5 June (1.70 and 1.66, respectively), whereas rapeseed was best separated in $|S_{HV}|$ and $|S_{HH} + S_{VV}|$ on 5 June and 29 June (1.55 and 1.30, respectively). For the other crops, $|S_{HV}|$ and $|S_{HH} - S_{VV}|$ (particularly on 5 June) resulted in the highest separabilities in this set of features. However, separabilities were not higher than those obtained with the backscatter coefficients and ratios with linear (H-V) basis.

4.3. Crop Classification

RF classification algorithm was used to evaluate the added value of quad-pol data by testing different polarization bases and polarimetric features in a multi-temporal crop classification scheme. Different classification models were built considering different inputs. First, model 0 consisted of VV-VH dual-pol configuration with just two backscattering coefficients in the two polarization channels. Then quad-pol configurations including three backscattering coefficients and their ratios were evaluated considering three polarization bases, *i.e.*, linear H-V, circular and linear 45° , leading to models 1, 2, and 3, respectively (Table 6).

Table 6. Classification accuracy measures using as input dual-pol *vs.* quad-pol with different polarization bases.

Model No	Dual VV-VH	Quad-Pol			Overall Accuracy	Kappa
		Linear H-V *	Circular †	Linear 45° ‡		
0	x				0.79	0.69
1		x			0.79	0.69
2			x		0.66	0.53
3				x	0.70	0.57

* σ_{HH}° , σ_{HV}° , σ_{VV}° , and their ratios; † σ_{RR}° , σ_{RL}° , σ_{LL}° , and their ratios; ‡ σ_{++}° , σ_{+-}° , σ_{--}° , and their ratios.

The same results were obtained using either the dual-pol VV-VH (model 0) or the quad-pol configuration in linear H-V basis (model 1), providing OA and Kappa values of 0.79 and 0.69, respectively. However, quad-pol data in circular or 45° bases lead to lower accuracies (Table 6), particularly in the circular case.

Figure 6 shows the accuracy obtained for individual crop classes on each model (0 to 3) representing the producer's and user's accuracy (%). PA represents the probability that a certain crop class on the ground is correctly classified, whereas UA refers to the probability that any field classified as a certain crop class in the image is actually this class on the ground. PA corresponds to errors of omission (fields of a certain class not classified as such) and UA to errors of commission (fields included erroneously in a certain class).




Figure 6. UA and PA for the different crops and classification schemes (models) tested.

The best PA results were achieved for sunflower and rapeseed. Sunflower obtained a PA of 100% in the four modes tested, and so did rapeseed in models 0, 2, and 3. These results are in agreement with the high separability values obtained for these two classes, except for rapeseed in model 1, where a high proportion of fields were erroneously classified as peas. UA results for these two crops were slightly lower than PA values, and were highest for models 0, 2, and 3 for rapeseed and model 3 for sunflower. Wheat and barley yielded high accuracies for models 0 and 1, with PA and UA values above 75%. The third cereal crop, oats, had lower PA accuracies (mostly due to some oat fields being classified as wheat) with values around 70% for models 0, 1, and 2 and even lower for model 3. The UA values of oats were above 75% for models 0 and 1 but dropped down to 50% for models 2 and 3.

Minor crops (*i.e.*, peas, vetch, and grasslands) had normally lower accuracies, since most classification models tested failed at classifying these crops. In particular, pea fields obtained the best results for model 0 with PA = 67% and UA = 50%; these values were lower for the other models tested. Vetch achieved even poorer results with a maximum PA of only 50% for model 1; circular and 45° bases resulted in even lower accuracies. The small field sizes of these two classes might be partly responsible of these poor results. Grasslands were also poorly classified with model 0 but its results improved clearly for model 1 and, especially for model 3, with PA values of 100%, although UA only reached 42%. This means that all grasslands test sites were classified as such, but several test fields of other classes (mostly wheat) were also incorrectly classified as grasslands. Finally, fallow fields had varying accuracies depending on the models tested. Overall, the high accuracies obtained with the VV-VH dual-pol configuration (model 0) and the quad-pol in 45° bases (model 3) seem very remarkable, with PA and UA values around 75% and 50%, respectively.

The inclusion of the different polarimetric features in the RF classification scheme improved classification accuracy measures in all cases (Table 7). In particular, the inclusion of coherence ($|\rho_{HH-VV}|$) and phase difference (ϕ_{HH-VV}) in model 4 outperformed the OA and Kappa values obtained with model 1 (with improvements of 0.05 in OA and 0.07 in Kappa). The other three models (models 5, 6, and 7) resulted in only minor accuracy enhancements. The best results were obtained when all the polarimetric features were used as input (model 8), with an OA of 0.86 and a Kappa value of 0.79. When compared to the VV-VH dual-pol configuration (model 0 in Table 6), these values represented improvements of 0.07 and 0.10 in terms of OA and Kappa, respectively.

Table 7. Classification accuracy measures when different polarimetric features were added to the H-V linear quad-pol data.

Model No	Feature Combination					Overall Accuracy	Kappa
	Linear H-V *	$ \rho_{HH-VV} $, ϕ_{HH-VV}	Pauli	α , H, A	α_1 , H, A		
4	x	x				0.84	0.76
5	x		x			0.81	0.72
6	x			x		0.82	0.73
7	x				x	0.82	0.73
8	x	x	x	x	x	0.86	0.79

* σ°_{HH} , σ°_{HV} , σ°_{VV} , and their ratios.

The results per crop (Figure 7) showed that polarimetric features contributed to slight improvements for wheat, barley, and oats; with PA and UA values increasing around 10% in the best cases. For wheat the addition of $|\rho_{HH-VV}|$ and ϕ_{HH-VV} provided the best results, whereas for barley it was Pauli features and for oats $|\rho_{HH-VV}|$ and ϕ_{HH-VV} and $\alpha/H/A$. Sunflower obtained good results regardless of the polarimetric features added, with highest accuracies for model 6 (PA = 100% and UA = 89%). In turn, rapeseed clearly benefited from the addition of polarimetric features; with models 4 and 5 having PA and UA values around 65% and models 6, 7, and 8 topping 100%. The poorest results were obtained for peas, where none of the polarimetric features improved the accuracy values obtained for the VV-VH dual-pol case (Figure 6); models 1, 6, and 7 obtained the same results and models 4 and 8 were unable to correctly classify a single pea field (Figure 7). On the other hand, vetch yielded PA values of 50% for all cases regardless of the polarimetric features added; in this crop UA values were lower, with a maximum of 36% for model 8. Grasslands were quite successfully classified, with PA values of 80% for models 1–7; however, these values were exceeded when quad-pol data were transformed to 45° basis (model 3 in Figure 6). Similarly, fallow fields were reasonably identified in model 3 (Figure 6). This class achieved lower PA values for models 4–6 (Figure 7), whereas it increased again for models 7 and 8. This corresponds to the higher separability achieved by α_1 for this class (Table 4). These results are also visible in the classification maps provided in Figure 8, where the results of model 0 and model 8 are compared. It can be observed that their similarity is very high, with differences corresponding mainly to grasslands and minor crops like vetch and peas.


**Figure 7.** UA and PA for the different crops and classification schemes (models) including polarimetric features.



Figure 8. Classification maps for a sample agricultural district: (a) corresponds to classification model 0 (dual pol) and (b) to model 8 (quad pol including all the polarimetric features).

5. Discussion

The analyses performed (descriptive analysis, separability study, and classification) highlight the importance of linear backscatter coefficient values for crop classification. Using just three scenes acquired in key dates, a VV-VH dual-pol configuration was sufficient for accurately classifying most crops in the area (*i.e.*, wheat, barley, oats, sunflower, and rapeseed). This result is remarkable and demonstrates the suitability of the Sentinel-1 nominal operational mode (dual-pol VV-VH) over land for agricultural applications. Although previous studies demonstrated the benefits of quad-pol data compared to single or dual-pol configurations for crop classification when just one acquisition date was available [22,42], when multi-temporal configurations were tested these differences were minor [8,43]. In fact, some studies [44,45] reported high classification accuracies with just three scenes acquired in key dates in dual-pol configurations, in coincidence with our results. Therefore, it seems that rather than a single-date quad-pol dataset, a multi-date dual-pol option provides enhanced crop classification accuracies.

However, results for minor crops (peas, vetch, grasslands, and, to a lesser extent, fallow) were not that successful and varied for the different models evaluated. It should be taken into account that the rather small size of fields of these classes (particularly peas and vetch) might have affected the accuracy of the calculation of some polarimetric features tested here, which required spatial averaging. On the other hand, the grasslands class can be very variable in terms of management practices; subdivision of this class into two or three classes according to their management would probably result in higher accuracies, but this could not be tested with our dataset. Similarly, fallow fields might also be difficult to identify because they can be very heterogeneous due to differences in weed management, previous crops cultivated, *etc.* Nonetheless, the classification based on V-H dual-pol data achieved an intermediate accuracy for peas, as did the quad-pol configuration for vetch. In turn, grasslands and fallow fields were accurately identified in some of the models tested, and these results are encouraging because of the heterogeneity of these classes in terms of management practices.

Overall, quad-pol data in different polarization bases (circular and 45° linear) showed worse results than those obtained with H-V linear basis. However, certain crops (*i.e.*, grasslands and fallow) showed enhanced accuracies at 45° basis. Regarding the inclusion of different polarimetric features, co-pol coherence ($|\rho_{HH-VV}|$) and phase difference (ϕ_{HH-VV}), clearly improved the overall accuracy

results obtained with quad-pol backscatter coefficients and ratios. Although, the other polarimetric features evaluated (Pauli and Cloude–Pottier decomposition features) showed some sensitivity to crop characteristics and good separabilities for some particular crops, their inclusion in the RF classifications did not result in clear improvements in the overall accuracy, probably because the information they provided was somehow redundant with that of the backscatter coefficients and ratios. Nonetheless, some improvements in the classification of some crops were observed after adding Pauli or Cloude–Pottier decomposition features. The inclusion of all the polarimetric features evaluated led to overall classification performance metrics of OA = 0.86 and Kappa = 0.79; these values represented improvements of 0.07 and 0.10 in terms of OA and Kappa, respectively, when compared to the VV-VH dual-pol configuration.

All in all, this approach is almost ready to be used to operationally classify agricultural areas and, for instance, to reduce the number of fields inspected for the EU CAP program by local administrations. The accuracies obtained here suggest the operational readiness of this technique, at least for identifying major crops. Further improvements need to be done to successfully classify minor crops with small field sizes and heterogeneous classes like grasslands and fallow fields.

6. Conclusions

The results of this study demonstrate that C-band SAR data can be effectively used for crop classification. Major crops in the area achieved high classification accuracies, and in particular cereal crops (wheat, barley, and oats) could be adequately identified, which is remarkable due to their similarities in terms of morphology and agricultural calendar. It was observed that the use of different polarimetric bases (circular and 45° linear) did not produce clear benefits in terms of overall classification accuracy, although improvements were reported in the identification of some particular crops (*i.e.*, grasslands and fallow). Regarding the addition of polarimetric features, co-pol coherence and phase difference clearly enhanced classification results, but Pauli and Cloude–Pottier decomposition features did not provide additional improvements. The classification using all the polarimetric features evaluated led to an overall accuracy of 0.86 and a Kappa value of 0.79; these values represented improvements of 0.07 and 0.10, respectively, when compared to the VV-VH dual-pol configuration. Hence, a VV-VH dual-pol configuration was still considered sufficient for accurately classifying major crops in the area as long as acquisitions in at least three key dates of the agricultural calendar were available. However, the method still needs to be adjusted to improve the classification of some crops that had small field sizes in this study (*i.e.*, peas and vetch), heterogeneous cover (*i.e.*, fallow and grasslands), and crops that are common in other parts of the world (e.g., corn, potato, or sugar beet). Today, Sentinel-1 data provide opportunities to make this application fully operational.

Acknowledgments: The Canadian Space Agency provided the RADARSAT-2 data through the Project SOAR-EU 6774.

Author Contributions: Arantzazu Larrañaga and Jesús Álvarez-Mozos conceived and designed this study. Arantzazu Larrañaga processed the data, and both Arantzazu Larrañaga and Jesús Álvarez-Mozos, analyzed the results obtained and contributed to the writing of this manuscript.

Conflicts of Interest: The authors declare no conflict of interest.

References

1. Boryan, C.; Yang, Z.; Mueller, R.; Craig, M. Monitoring US agriculture: the US department of agriculture, national agricultural statistics service, cropland data layer program. *Geocarto Int.* **2011**, *26*, 341–358. [[CrossRef](#)]
2. Schmedtmann, J.; Campagnolo, M. Reliable crop identification with satellite imagery in the context of common agriculture policy subsidy control. *Remote Sens.* **2015**, *7*, 9325–9346. [[CrossRef](#)]
3. Becker-Reshef, I.; Justice, C.; Sullivan, M.; Vermote, E.; Tucker, C.; Anyamba, A.; Small, J.; Pak, E.; Masuoka, E.; Schmaltz, J.; *et al.* Monitoring global croplands with coarse resolution earth observations: The global agriculture monitoring (GLAM) project. *Remote Sens.* **2010**, *2*, 1589–1609. [[CrossRef](#)]

4. Chuvieco, E.; Huete, A. *Fundamentals of Satellite Remote Sensing*; CRC Press: Boca Raton, FL, USA, 2009.
5. Whitcraft, A.K.; Vermote, E.F.; Becker-Reshef, I.; Justice, C.O. Cloud cover throughout the agricultural growing season: Impacts on passive optical earth observations. *Remote Sens. Environ.* **2015**, *156*, 438–447. [[CrossRef](#)]
6. Lobell, D.B.; Asner, G.P. Cropland distributions from temporal unmixing of MODIS data. *Remote Sens. Environ.* **2004**, *93*, 412–422. [[CrossRef](#)]
7. Drusch, M.; del Bello, U.; Carlier, S.; Colin, O.; Fernandez, V.; Gascon, F.; Hoersch, B.; Isola, C.; Laberinti, P.; Martimort, P.; *et al.* Sentinel-2: ESA's optical high-resolution mission for GMES operational services. *Remote Sens. Environ.* **2012**, *120*, 25–36. [[CrossRef](#)]
8. McNairn, H.; Champagne, C.; Shang, J.; Holmstrom, D.; Reichert, G. Integration of optical and Synthetic Aperture Radar (SAR) imagery for delivering operational annual crop inventories. *ISPRS J. Photogramm. Remote Sens.* **2009**, *64*, 434–449. [[CrossRef](#)]
9. Ulaby, F.T.; Long, D. *Microwave Radar and Radiometric Remote Sensing*; The University of Michigan Press: Ann Arbor, MI, USA, 2014.
10. Grunes, M.R.; Pottier, E. Quantitative comparison of classification capability: Fully polarimetric *versus* dual and single-polarization SAR. *IEEE Trans. Geosci. Remote Sens.* **2001**, *39*, 2343–2351.
11. Skriver, H. Crop classification by multitemporal C- and L-band single- and dual-polarization and fully polarimetric SAR. *IEEE Trans. Geosci. Remote Sens.* **2012**, *50*, 2138–2149. [[CrossRef](#)]
12. López-Martínez, C.; Ferro-Famil, L.; Pottier, E. *PolSARpro v4.0 Polarimetry Tutorial*; European Space Agency: Paris, France, 2005.
13. Loosvelt, L.; Peters, J.; Skriver, H.; De Baets, B.; Verhoest, N.E.C. Impact of reducing polarimetric SAR input on the uncertainty of crop classifications based on the random forests algorithm. *IEEE Trans. Geosci. Remote Sens.* **2012**, *50*, 4185–4200. [[CrossRef](#)]
14. Loosvelt, L.; Peters, J.; Skriver, H.; Lievens, H.; Van Coillie, F.M.B.; De Baets, B.; Verhoest, N.E.C. Random Forests as a tool for estimating uncertainty at pixel-level in SAR image classification. *Int. J. Appl. Earth Obs. Geoinf.* **2012**, *19*, 173–184. [[CrossRef](#)]
15. Lee, J.S.; Pottier, E. *Polarimetric Radar Imaging: From Basics to Applications*; CRC Press: Boca Raton, FL, USA, 2009.
16. McNairn, H.; Brisco, B. The application of C-band polarimetric SAR for agriculture: A review. *Can. J. Remote Sens.* **2004**, *30*, 525–542. [[CrossRef](#)]
17. Satalino, G.; Mattia, F.; Le Toan, T.; Rinaldi, M. Wheat crop mapping by using ASAR AP data. *IEEE Trans. Geosci. Remote Sens.* **2009**, *47*, 527–530. [[CrossRef](#)]
18. Cloude, S.R.; Pottier, E. A review of target decomposition theorems in radar polarimetry. *IEEE Trans. Geosci. Remote Sens.* **1996**, *34*, 498–518. [[CrossRef](#)]
19. Lopez-Sanchez, J.M.; Ballester-Berman, J.D.; Hajnsek, I. First results of rice monitoring practices in Spain by means of time series of TerraSAR-X Dual-Pol images. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* **2011**, *4*, 412–422. [[CrossRef](#)]
20. Alberga, V. A study of land cover classification using polarimetric SAR parameters. *Int. J. Remote Sens.* **2007**, *28*, 3851–3870. [[CrossRef](#)]
21. Rodrigues, A.; Corr, D.G.; Pottier, E.; Ferro-Famil, L.; Hoekman, D.H. Land cover classification using polarimetric SAR data. In Proceedings of the Workshop on POLinSAR—Applications of SAR Polarimetry and Polarimetric Interferometry (ESA SP-529), Frascati, Italy, 14–16 January 2003.
22. Del Frate, F.; Schiavon, G.; Solimini, D.; Borgeaud, M.; Hoekman, D.H.; Vissers, M.A.M. Crop classification using multiconfiguration C-band SAR data. *IEEE Trans. Geosci. Remote Sens.* **2003**, *41*, 1611–1619. [[CrossRef](#)]
23. Jiao, X.; Kovacs, J.M.; Shang, J.; McNairn, H.; Walters, D.; Ma, B.; Geng, X. Object-oriented crop mapping and monitoring using multi-temporal polarimetric RADARSAT-2 data. *ISPRS J. Photogramm. Remote Sens.* **2014**, *96*, 38–46. [[CrossRef](#)]
24. Lopez-Sanchez, J.M.; Vicente-Guijalba, F.; Ballester-Berman, J.D.; Cloude, S.R. Polarimetric response of rice fields at C-Band: Analysis and phenology retrieval. *IEEE Trans. Geosci. Remote Sens.* **2014**, *52*, 2977–2993. [[CrossRef](#)]
25. Moran, M.S.; Alonso, L.; Moreno, J.F.; Mateo, M.P.C.; Fernando De La Cruz, D.; Montoro, A. A RADARSAT-2 quad-polarized time series for monitoring crop and soil conditions in Barrax, Spain. *IEEE Trans. Geosci. Remote Sens.* **2012**, *50*, 1057–1070. [[CrossRef](#)]

26. Yang, H.; Chen, E.; Li, Z.; Zhao, C.; Yang, G.; Pignatti, S.; Casa, R.; Zhao, L. Wheat lodging monitoring using polarimetric index from RADARSAT-2 data. *Int. J. Appl. Earth Obs. Geoinf.* **2015**, *34*, 157–166. [[CrossRef](#)]
27. De Wit, A.J.W.; Clevers, J.G.P.W. Efficiency and accuracy of per-field classification for operational crop mapping. *Int. J. Remote Sens.* **2004**, *25*, 4091–4112. [[CrossRef](#)]
28. Sabour, S.M.T.; Lohmann, P.; Soergel, U. *Monitoring Agricultural Activities Using ASAR ENVISAT Data*; European Space Agency: Paris, France, 2007.
29. Wang, D.; Lin, H.; Chen, J.; Zhang, Y.; Zeng, Q. Application of multi-temporal ENVISAT ASAR data to agricultural area mapping in the Pearl River Delta. *Int. J. Remote Sens.* **2010**, *31*, 1555–1572. [[CrossRef](#)]
30. Larranaga, A.; Alvarez-Mozos, J.; Albizua, L.; Peters, J. Backscattering behavior of rain-fed crops along the growing season. *IEEE Geosci. Remote Sens. Lett.* **2013**, *10*, 386–390. [[CrossRef](#)]
31. Blaes, X.; Vanhalle, L.; Defourny, P. Efficiency of crop identification based on optical and SAR image time series. *Remote Sens. Environ.* **2005**, *96*, 352–365. [[CrossRef](#)]
32. Lopes, A.; Nezry, E.; Touzi, R.; Laur, H. Structure detection and statistical adaptive speckle filtering in SAR images. *Int. J. Remote Sens.* **1993**, *14*, 1735–1758. [[CrossRef](#)]
33. Lee, J.; Ainsworth, T.; Kelly, J. Statistical evaluation and bias removal of multi-look effect on Entropy/alpha/Anisotropy in polarimetric target decomposition. In Proceedings of the 7th European Conference on Synthetic Aperture Radar (EUSAR), Friedrichshafen, Germany, 2–5 June 2008.
34. Swain, P. *Two Effective Feature Selection Criteria for Multispectral Remote Sensing*; LARS Technical Note 042673; Laboratory for Applications of Remote Sensing (LARS): West Lafayette, IN, USA, 1973.
35. Skriver, H. Signatures of polarimetric parameters and their implications on land cover classification. In Proceedings of the 2007 IEEE International Geoscience and Remote Sensing Symposium, Barcelona, Spain, 23–27 July 2007.
36. Breiman, L. Random Forests. *Mach. Learn.* **2001**, *45*, 5–32. [[CrossRef](#)]
37. Pal, M. Random forest classifier for remote sensing classification. *Int. J. Remote Sens.* **2005**, *26*, 217–222. [[CrossRef](#)]
38. Waske, B.; Braun, M. Classifier ensembles for land cover mapping using multitemporal SAR imagery. *Remote Sens.* **2009**, *64*, 450–457. [[CrossRef](#)]
39. He, H.; Garcia, E.A. Learning from imbalanced data. *IEEE Trans. Knowl. Data Eng.* **2002**, *21*, 321–357.
40. Chawla, N.V.; Bowyer, K.W.; Hall, L.O.; Kegelmeyer, W.P. SMOTE: Synthetic Minority Over-sampling Technique. *J. Artif. Intell. Res.* **2009**, *16*, 450–457.
41. Ferrazzoli, G.; Guerriero, P.; Schiavon, L. Experimental and model investigation on radar classification capability. *IEEE Trans. Geosci. Remote Sens.* **1999**, *37*, 960–968. [[CrossRef](#)]
42. Lee, M.; Liew, K.Y.; Kwok, S.C.; Nakayama, L.K. Land cover classification using NASA/JPL polarimetric synthetic aperture radar (POLSAR) data. In Proceedings of the 22nd Asian Conference on Remote Sensing, Singapore, 5–9 November 2001.
43. Skriver, H.; Mattia, F.; Satalino, G.; Balenzano, A.; Pauwels, V.R.N.; Verhoest, N.E.C.; Davidson, M. Crop classification using short-revisit multitemporal SAR data. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* **2011**, *4*, 423–431. [[CrossRef](#)]
44. Stankiewicz, K.A. The efficiency of crop recognition on ENVISAT ASAR images in two growing seasons. *IEEE Trans. Geosci. Remote Sens.* **2006**, *44*, 806–814. [[CrossRef](#)]
45. McNairn, H.; Champagne, C. The contribution of ALOS PALSAR multipolarization and polarimetric data to crop classification. *IEEE Trans. Geosci. Remote Sens.* **2009**, *47*, 3981–3992. [[CrossRef](#)]



© 2016 by the authors; licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC-BY) license (<http://creativecommons.org/licenses/by/4.0/>).

4. Discusión y conclusión general

Aunque la teledetección radar se comenzó a desarrollar hace ya cuatro décadas, sus aplicaciones operacionales son aún mucho menores que las basadas en teledetección óptica. En los últimos años la disponibilidad de este tipo de imágenes se ha incrementado debido a la puesta en marcha de misiones como Sentinel-1A, ALOS-2/PALSAR o la constelación COSMO-SkyMed y en un futuro próximo esta tendencia continuará con el lanzamiento de satélites como PAZ o SAOCOM-1A previstos para este mismo 2016. Es por ello que el desarrollo de aplicaciones basadas en este tipo de imágenes resulta de gran interés. En el ámbito agrícola, una de las principales aplicaciones de la teledetección es la clasificación de cultivos por lo que este trabajo se ha centrado en investigar la viabilidad de este tipo de observaciones para esta aplicación en concreto. A continuación, se desarrollan las conclusiones generales en base a los objetivos inicialmente definidos.

Los cultivos mayoritarios de las distintas zonas de estudio han sido cereales como el trigo, la cebada y la avena. Los cereales presentan un comportamiento similar durante casi la totalidad de su periodo de desarrollo vegetativo, por lo que en este tipo de estudios frecuentemente, se agrupan en una única clase (Brisco y Brown, 1995; Castillejo-González et al., 2009; McNairn y Champagne, 2009; McNairn et al., 2009; Waske y van der Linden, 2008). En el primer trabajo de esta tesis (Larrañaga et al., 2010), se optó también por unir los cereales en una única clase debido a que en la época en la que se adquirieron las imágenes radar utilizadas en la clasificación (ALOS-1/PALSAR, de marzo y mayo), los cereales aun no mostraban diferencias fenológicas aparentes y se confundían mucho. Más adelante, en Larrañaga et al. (2011a), al incorporar una imagen óptica de verano a las imágenes radar de marzo y mayo, se decidió clasificar los cereales de forma independiente. En el resto de trabajos presentados (Larrañaga et al., 2011b; Larrañaga et al., 2013 y Larrañaga y Álvarez-Mozos, 2016), al contar con una serie multitemporal más completa, y además adquirida en banda-C, los cereales se clasificaron de forma independiente, tal y como lo hicieron por ejemplo Loosvelt et al. (2012) y Skriver (2012). Los resultados obtenidos pusieron de manifiesto el potencial de este tipo de observaciones para detectar diferencias fenológicas y morfológicas en estos cultivos, lo que se considera muy relevante.

El número de imágenes necesarias para obtener una buena fiabilidad en la clasificación, depende del tipo de imagen (óptica o radar), su fecha de adquisición y en el caso de las imágenes radar, de la configuración de las escenas utilizadas. Las imágenes ópticas, siempre y cuando la fecha de adquisición sea adecuada, son capaces de obtener muy buenos resultados, incluso cuando se clasifican individualmente. En Larrañaga et al. (2011b), se alcanzó una FG e índice de Kappa de 80% y 0.70 respectivamente, utilizando una única imagen Landsat 5-TM de junio. Por contra, en Larrañaga et al. (2011a), utilizando una imagen Landsat 5-TM de agosto, la FG no superó el 58%. McNairn et al. (2009a) utilizando una única imagen óptica para clasificar 5 tipos de cultivos, alcanzaron una FG de 70% y un índice de Kappa superior a 0.60. En ese mismo trabajo se destacó la importancia de la fecha de adquisición, ya que la FG no superó el 53.7% al utilizar imágenes tempranas de verano.

En el caso de los sensores radar, si bien las imágenes de configuración simple se utilizaron en trabajos iniciales, se vio que el uso de una única imagen de estas características resultaba claramente insuficiente para clasificar cultivos con una fiabilidad mínima (Lee et al., 2001; Waske y van der Linden, 2008). En Larrañaga et al. (2011b), los resultados obtenidos a partir de imágenes radar de una única polarización en banda-C, fueron mejorando a medida que aumentó el número de imágenes utilizadas, pasando la FG y el índice de Kappa de 43% a 65% y de 0.31 a 0.55, respectivamente. El mejor resultado se obtuvo con la combinación de cuatro imágenes ERS-2 adquiridas entre abril y junio.

Estudios basados en una adquisición única pero de polarización múltiple han ofrecido resultados mejores, pero aun inferiores a los obtenidos a partir de una imagen óptica. Por ejemplo, McNairn et al. (2009b) utilizando una única imagen RADARSAT-2 polarimétrica obtuvieron fiabilidades inferiores al 60% y en general un 20-25% inferiores a las obtenidas con una imagen óptica (adquiridas en la misma fecha). De forma similar, Larrañaga et al. (2013) utilizando una única imagen radar polarimétrica adquirida en diferentes fechas (entre marzo y junio), las clasificaciones fueron en general pobres, obteniendo en el mejor de los casos, con la imagen de principios de junio, una FG de 67% y Kappa de 0.46. Una vez más, la fecha de adquisición resultó clave siendo principios de junio la fecha óptima, debido a que la mayoría de los cultivos se encontraban totalmente desarrollados y sus diferencias eran máximas, al igual que apreció Skriver (2012). Otros estudios basados en una única adquisición radar, obtuvieron resultados similares (Del Frate et al., 2003; McNairn et al., 2009a).

Las clasificaciones multitemporales de estas mismas escenas RADARSAT-2 polarimétricas, alcanzaron resultados superiores (Larrañaga et al., 2013). En concreto, la combinación de las escenas adquiridas en mayo y junio llegaron a una FG y Kappa de 75% y 0.60 respectivamente. Al incorporar la escena de finales de junio el resultado mejoró (FG de 79% y Kappa de 0.67). La cuarta escena, de abril, consiguió mejorar sólo ligeramente el resultado (FG de 80% y Kappa de 0.67). Sin embargo, la inclusión de la imagen de marzo, redujo las fiabilidades obtenidas (FG de 78% y Kappa de 0.65). Este mismo efecto de saturación también se vio en Skriver (2012) y las fiabilidades alcanzadas con las tres primeras escenas, fueron muy parecidas a las que se obtuvieron en (Loosvelt et al., 2012a; McNairn et al., 2009a; Skriver, 2012; Waske y van der Linden, 2008).

En lo que respecta a la complementariedad óptico-radar, en dos de los trabajos presentados (Larrañaga et al., 2011a; Larrañaga et al., 2011b) se analizaron los resultados obtenidos al combinar en la clasificación una única imagen óptica con una o varias escenas radar. En el primer caso las imágenes radar utilizadas fueron polarimétricas y en banda-L (ALOS-1/PALSAR), mientras que en el segundo fueron imágenes de configuración simple en banda-C (ERS-2, polarización VV). En ambos casos, se vio que la incorporación de una o varias escenas radar mejoró el resultado inicial obtenido a partir de la imagen multispectral sola. En Larrañaga et al. (2011a) la FG e índice Kappa pasaron de 58% a 60% y de 0.24 a 0.33 respectivamente, mientras que en Larrañaga et al. (2011b) la mejora fue aún más significativa, pasando de 76% a 82% (FG) y de 0.64 a 0.75 (Kappa). En este segundo caso, además de evaluar la fiabilidad global de la clasificación, se analizó también la fiabilidad a nivel de cultivo, obteniendo mejoras muy significativas para algunos cultivos concretos. Si bien las imágenes ópticas no conseguían discriminar adecuadamente los cultivos minoritarios (guisante, barbecho, habas y colza), las

combinaciones óptico-radar fueron capaces de identificar dichos cultivos de forma sorprendente. Las mejoras observadas en estos dos trabajos fueron acorde con lo que obtuvieron Brisco y Brown (1995) o McNairn et al. (2009a).

Un aspecto clave a la hora de utilizar imágenes radar para clasificar cultivos es su polarización. En este trabajo se ha constatado que el canal de polarización más interesante o informativo es el HV. En Larrañaga et al. (2010) la polarización HV fue la que mejor separabilidad o distancia normalizada (Swain y Davis, 1978) media obtuvo tanto para cultivos de secano como de regadío. En Larrañaga et al. (2013) se utilizó otra medida de separabilidad, la distancia de Jeffries-Matusita (JM) (Swain, 1973), que fue máxima para las polarizaciones HV y VV. En este último trabajo (Larrañaga et al., 2013) además de la separabilidad se analizaron también las variaciones temporales del coeficiente de retrodispersión en las distintas polarizaciones para los cultivos estudiados. Los mayores rangos de variación se alcanzaron con las polarizaciones HV y VV. El coeficiente de retrodispersión HH presentó un rango de variación menor que los dos anteriores, indicando una menor sensibilidad a la vegetación y una mayor influencia de variables del suelo (rugosidad y/o humedad). Esto mismo observaron Waske y van der Linden (2008), que en la polarización HH en banda-C y utilizando ángulos de incidencia medios o bajos (como los utilizados en esta tesis) dominaba la contribución del suelo. Otros estudios también identificaron las polarizaciones HV y VV como las más apropiadas para identificar los cultivos cuando se trabaja en la banda-C (Del Frate et al., 2003; Skriver, 2012). Según Lee et al. (2001), y McNairn et al. (2009b), la polarización HV resultó ser la mejor opción para clasificar los cultivos tanto en la banda-C (Lee et al., 2001) como en la banda-L (McNairn et al., 2009b).

En el primer y en el último artículo de esta tesis (Larrañaga et al., 2010 y Larrañaga y Álvarez-Mozos, 2016) se valoró el uso de distintos parámetros polarimétricos y bases de polarización. En Larrañaga et al. (2010) se seleccionaron los parámetros más interesantes (σ_{HH}^0 , σ_{HV}^0 , α , $|\rho_{HHVV}|$, $\sigma_{HV}^0/\sigma_{VV}^0$ y $\sigma_{RR}^0/\sigma_{RL}^0$) en base a los resultados aportados por la matriz de correlación entre parámetros y la separabilidad media de los cultivos estudiados. Al igual que en Loosvelt et al. (2012a) se vio que era conveniente hacer una selección previa de los parámetros a utilizar, ya que se obtenían resultados similares utilizando esta selección o utilizando todos los parámetros considerados inicialmente. Por otro lado, en Larrañaga y Álvarez-Mozos (2016), las clasificaciones basadas en configuración dual-pol (VV-VH) obtuvieron unos resultados similares a los alcanzados con observaciones quad-pol en base de polarización lineal (FG de 79% y Kappa de 0.69). La inclusión de los parámetros polarimétricos, en particular $|\rho_{HHVV}|$ y Φ_{HHVV} , mejoraron sensiblemente los resultados globales obtenidos. Estas mejoras se observaron también en la identificación de algunos cultivos en concreto, sin embargo, los cultivos mayoritarios como los cereales, colza y girasol, obtuvieron también una buena fiabilidad utilizando únicamente los datos dual-pol y las mejoras observadas en estos casos fueron escasas. Stankiewicz (2006) y McNairn et al. (2009b) utilizando tres escenas de polarización simple o doble adquiridas entre mayo y julio, alcanzaron también fiabilidades muy buenas (FG de 75-80%).

Por último, el algoritmo de clasificación utilizado resultó también determinante. En los trabajos iniciales de esta tesis (Larrañaga et al., 2010 y Larrañaga et al., 2011a y b) se optó por utilizar el clasificador de máxima verosimilitud (MLC) y el de Mahalanobis. Para su elección, se consultaron diferentes estudios que utilizaban imágenes radar o la combinación de imágenes

ópticas y radar para clasificar los cultivos (Ban, 2003; McNairn et al., 2009a; Michelson, 2000; Waske y Braun, 2009). Más adelante se constató que varios autores (Bruzzone et al., 2004; Del Frate et al., 2003; McNairn et al., 2009a; Waske y Braun, 2009) coincidían en que cuando se trabajaba con imágenes radar era conveniente evitar algoritmos de clasificación diseñados para los datos con distribuciones normales (como por ejemplo MLC o Mahalanobis), puesto que los datos radar (coeficientes de retrodispersión y bandas derivadas) no se ajustan necesariamente a esa distribución. Por este motivo se optó por utilizar un algoritmo de clasificación basado en técnicas de aprendizaje automático conjunto (ensemble machine learning) denominado Random Forest (RF), (Breiman, 2001).

Los resultados obtenidos con los distintos algoritmos de clasificación (MLC, Mahalanobis y RF) no fueron directamente comparables ya que correspondían a distintas zonas y se utilizaron escenas de distintas fechas y características en cada caso. Aun así, debido a la versatilidad para trabajar con cualquier tamaño y tipo de datos, a su reducido tiempo computacional y a la fiabilidad de los resultados obtenidos se considera que RF resultó ser el más adecuado de todos los aquí estudiados. En cuanto a las áreas de entrenamiento (training sets) utilizadas en los algoritmos de clasificación, se vio que era importante considerar un mismo número representativo de muestras para cada cultivo para evitar favorecer las clases mayoritarias y obtener así unos resultados de clasificación más fiables (Waske y Braun, 2009).

Como reflexión final, los resultados obtenidos han demostrado que cuando se utilizan observaciones radar para clasificar cultivos la multitemporalidad y la fecha de adquisición de las escenas son características más importantes que su información polarimétrica. Asimismo, hay que tener presente las limitaciones que presentan los sensores polarimétricos, ya que debido a la complejidad de sus datos, almacenan grandes volúmenes de información y tanto la cobertura como el periodo de revisita se ven reducidas. En base a todo lo anteriormente mencionado, se puede concluir que la opción dual (VV-VH) puede ser una alternativa interesante para esta aplicación, ya que al almacenar menor cantidad de datos, cuentan con un periodo de revisita menor, favoreciendo así la multitemporalidad de las adquisiciones.

Este aspecto es muy interesante y más ahora que Sentinel-1A y 1B (satélites radar que trabajan en la banda-C, lanzados en 2014 y 2016 por la Agencia Espacial Europea, ESA) están trabajando en modo de polarización doble, con una resolución adecuada para este tipo de aplicaciones y sus imágenes se distribuyen libremente desde la web (<https://scihub.esa.int/dhus/>). Además, la propia ESA proporciona herramientas libres (Sentinel-1 Toolbox) para el procesamiento de este tipo de imágenes.

Con todo, los resultados de esta tesis demuestran la viabilidad del uso de observaciones radar para identificar de forma operativa los principales cultivos de la zona. Este hecho, reduciría en parte el número de inspecciones de las declaraciones PAC que cada año realiza el organismo competente.

Apéndice

La siguiente tabla recoge el factor de impacto de las revistas y áreas temáticas correspondientes a las publicaciones que se recogen en la tesis.

Tabla 6. Factor de impacto de las revistas que componen la tesis.

	Revista de Teledetección*	Canadian Journal of Remote Sensing	IEEE Geoscience and Remote Sensing Letters	Remote Sensing Open Access
	<i>Larrañaga et al., 2010b</i>	<i>Larrañaga et al., 2011</i>	<i>Larrañaga et al., 2013</i>	<i>Larrañaga et al., 2016</i>
Factor de impacto (JRC 2014)	-	1.727	2.095	3.180
Cuartil	-	Q2 (12/28)	Q1 (57/249)	Q1 (5/28)
Categoría	-	<i>Remote Sensing</i>	<i>Electrical and Electronics Engineering</i>	<i>Remote Sensing</i>

*Indexada en el Catálogo LATINDEX y en Scopus, y con revisión por pares.

Referencias

- Alberga, V. (2007). A study of land cover classification using polarimetric SAR parameters. *International Journal of Remote Sensing*, 28(17), 3851–3870.
<http://doi.org/10.1080/01431160601075541>
- Attema, E., Desnos, Y.-L., & Duchossois, G. (2000). Synthetic Aperture Radar in europe: ERS, Envisat,, and Beyond. *Johns Hopkins Apl. Technical Digest*, 21(1), 156–161.
- Ban, Y. (2003). Synergy of multitemporal ERS-1 SAR and Landsat TM data for classification of agricultural crops. *Canadian Journal of Remote Sensing*, 29(4), 518–526.
<http://doi.org/10.5589/m03-014>
- Barbosa P.M., Casterad M.A., H. J. (1996). Performance of several Landsat TM images classification methods for crop extent estimates in an irrigation district. *International Journal of Remote Sensing*, 17(18), 3665–3674.
- Belgiu, M., & Drăguț, L. (2016). Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 114, 24–31.
<http://doi.org/10.1016/j.isprsjprs.2016.01.011>
- Boryan, C., Yang, Z., Mueller, R., & Craig, M. (2011). Monitoring US agriculture: the US Department of Agriculture, National Agricultural Statistics Service, Cropland Data Layer Program. *Geocarto International*.
- Bouman, B. A. M., & Uenk, D. (1992). Crop classification possibilities with radar in ERS-1 and JERS-1 configuration. *Remote Sensing of Environment*, 40(1), 1–13.
[http://doi.org/10.1016/0034-4257\(92\)90122-Z](http://doi.org/10.1016/0034-4257(92)90122-Z)
- Breiman, L. (2001). Random Forests. *Machine Learning*, 45(1), 5–32.
<http://doi.org/10.1023/A:1010933404324>
- Bruzzone, L., Marconcini, M., Wegmuller, U., & Wiesmann, A. (2004). An advanced system for the automatic classification of multitemporal SAR images. *IEEE Transactions on Geoscience and Remote Sensing*, 42(6), 1321–1334.
<http://doi.org/10.1109/TGRS.2004.826821>
- Chander, G., Markham, B. L., & Helder, D. L. (2009). Summary of current radiometric calibration coefficients for Landsat MSS, TM, ETM+, and EO-1 ALI sensors. *Remote Sensing of Environment*, 113(5), 893–903. <http://doi.org/10.1016/j.rse.2009.01.007>
- Chavez, P. S. (1996). Image-based atmospheric corrections. Revisited and improved. *Photogrammetric Engineering and Remote Sensing*, 62(9), 1025–1036.
- Chuvieco, E. (2002). *Teledetección ambiental: La observación de la Tierra desde el Espacio*. Editorial Ariel Ciencia. Barcelona.
- Chuvieco, E., & Hantson, S. (2010). *Procesamiento estándar de imágenes Landsat*.

- Cohen, J. (1960). A Coefficient of Agreement for Nominal Scales. *Educational and Psychological Measurement*, 20(1), 37–46. <http://doi.org/10.1177/001316446002000104>
- Conrad, C., Fritsch, S., Zeidler, J., Rücker, G., & Dech, S. (2010). Per-Field Irrigated Crop Classification in Arid Central Asia Using SPOT and ASTER Data. *Remote Sensing*, 2(4), 1035–1056. <http://doi.org/10.3390/rs2041035>
- De Wit, A. J. W., & Clevers, J. G. P. W. (2004). Efficiency and accuracy of per-field classification for operational crop mapping. *International Journal of Remote Sensing*, 25(20), 4091–4112. <http://doi.org/10.1080/01431160310001619580>
- Del Frate, F., Schiavon, G., Solimini, D., Borgeaud, M., Hoekman, D. H., & Vissers, M. a M. (2003). Crop classification using multiconfiguration C-band SAR data. *IEEE Transactions on Geoscience and Remote Sensing*, 41(7 PART I), 1611–1619. <http://doi.org/10.1109/TGRS.2003.813530>
- Dong, Y., Milne, A. K., & Forster, B. C. (2001). Segmentation and classification of vegetated areas using polarimetric SAR image data. *IEEE Transactions on Geoscience and Remote Sensing*, 39(2), 321–329. <http://doi.org/10.1109/36.905240>
- Franklin S.E. and Wulder M.A. (2002). Remote sensing methods in medium spatial resolution satellite data land cover classification of large areas. *Progress in Physical Geography*, 26(2), 173–205.
- Gallego F.J. (2004). Remote sensing and land cover area estimation. *International Journal of Remote Sensing*, 25(15), 3019–3047.
- Gieske A., Salemi H.R., Miranzadeh M., Torabi M., M. A. R. and A. M. (2006). Crop and land cover classification in Iran using Landsat-7 imagery. *International Journal of Remote Sensing*, 19, 4117–4134.
- Hellden. (1980). *A test of Landsat-2 imagery and digital data for thematic mapping illustrated by an environmental study in Northern Kenya*.
- Jiao, X., Kovacs, J. M., Shang, J., McNairn, H., Walters, D., Ma, B., & Geng, X. (2014). Object-oriented crop mapping and monitoring using multi-temporal polarimetric RADARSAT-2 data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 96, 38–46.
- Landis, J.R. and Koch, G. G. (1977). The measurement of observer agreement for categorical data. *Biometrics*, 33, 159–174.
- Larrañaga, A., Alvarez-Mozos, J., Albizua, L., & Peters, J. (2013). Backscattering behavior of rain-fed crops along the growing season. *IEEE Geoscience and Remote Sensing Letters*, 10(2), 386–390. <http://doi.org/10.1109/LGRS.2012.2205660>
- Larrañaga, A., Albizua, L., Álvarez-mozos, J. (2010). Clasificación de cultivos en la zona media de Navarra mediante imágenes radar polarimétricas. *Revista de Teledetección*, 34, 77–88.
- Lee, K.Y., Liew, S.C., Kwoh, L.K., Nakayama, M. (2001). Land cover classification using NASA/JPL polarimetric synthetic aperture radar (POLSAR) data. In *In Proceedings of the 22nd Asian*

Conference on Remote Sensing, Singapore, 5-9 November, 2001 (pp. 1–6). Paper presented at the 22nd Asian Conference on Remote Sensing.

Leránz Goñi, A., & Albizua Huarte, L. (1998). Estimación de superficies cultivadas en Navarra. *Mapping*. eGeoMapping. Retrieved from <http://dialnet.unirioja.es/servlet/articulo?codigo=2902551>

Lillesand, T. (2000). *Remote Sensing and Image Interpretation*.

Loosvelt, L., Peters, J., Skriver, H., De Baets, B., & Verhoest, N. E. C. (2012). Impact of reducing polarimetric SAR input on the uncertainty of crop classifications based on the random forests algorithm. *IEEE Transactions on Geoscience and Remote Sensing*, 50(10 PART2), 4185–4200.

Loosvelt, L., Peters, J., Skriver, H., Lievens, H., Van Coillie, F. M. B., De Baets, B., & Verhoest, N. E. C. (2012). Random Forests as a tool for estimating uncertainty at pixel-level in SAR image classification. *International Journal of Applied Earth Observation and Geoinformation*, 19, 173–184. <http://doi.org/10.1016/j.jag.2012.05.011>

Lopes, A., Nezry, E., Touzi, R., & Laur, H. (1993). Structure detection and statistical adaptive speckle filtering in SAR images. *International Journal of Remote Sensing*, 14(9), 1735–1758. <http://doi.org/10.1080/01431169308953999>

Lopez-Sanchez, J. M., Ballester-Berman, J. D., & Hajnsek, I. (2011). First Results of Rice Monitoring Practices in Spain by Means of Time Series of TerraSAR-X Dual-Pol Images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 4(2), 412–422. <http://doi.org/10.1109/JSTARS.2010.2047634>

McNairn, H., Champagne, C., Shang, J., Holmstrom, D., & Reichert, G. (2009). Integration of optical and Synthetic Aperture Radar (SAR) imagery for delivering operational annual crop inventories. *ISPRS Journal of Photogrammetry and Remote Sensing*, 64(5), 434–449.

McNairn, H., Shang, J., Champagne, C., & Jiao, X. (2009). TerraSAR-X and RADARSAT-2 for crop classification and acreage estimation. In *International Geoscience and Remote Sensing Symposium (IGARSS)* (Vol. 2).

Michelson, D. (2000). Comparison of Algorithms for Classifying Swedish Landcover Using Landsat TM and ERS-1 SAR Data. *Remote Sensing of Environment*, 71(1), 1–15. [http://doi.org/10.1016/S0034-4257\(99\)00024-3](http://doi.org/10.1016/S0034-4257(99)00024-3)

Morena, L. C., James, K. V., & Beck, J. (2004). An introduction to the RADARSAT-2 mission. *Canadian Journal of Remote Sensing*, 30(3), 221–234.

Quegan, S. et al. (2003). Crop classification with multitemporal polarimetric SAR data. In *Proc. of ESA POLINSAR 2003 Workshop*.

Rodrigues, A., Corr, D. G., Pottier, E., Ferro-Famil, L., & Hoekman, D. H. (2003). Land cover classification using polarimetric SAR data. *Proceedings of the Workshop on POLinSAR - Applications of SAR Polarimetry and Polarimetric Interferometry, Eur. Sp. Agency, Special Publ. ESA SP-529, Pp. 1-10*. Retrieved from

http://www.researchgate.net/publication/40798040_Land_cover_classification_using_polarimetric_SAR_data

- Rosenqvist, A., Shimada, M., Ito, N., & Watanabe, M. (2007). ALOS PALSAR: A Pathfinder Mission for Global-Scale Monitoring of the Environment. *IEEE Transactions on Geoscience and Remote Sensing*, 45(11), 3307–3316. <http://doi.org/10.1109/TGRS.2007.901027>
- Rosenqvist, A., Shimada, M., Manabu, W., Takeo, T., & Yamauchi, K. (2004). Implementation of Systematic Data Observation Strategies for ALOS PALSAR, PRISM and AVNIR-2. In *International Geoscience and Remote Sensing Symposium (IGARSS'04), Anchorage, USA*. (p. 4).
- Sabour, S. M. T., Lohmann, P., & Soergel, U. (2007). Monitoring agricultural activities using ASAR ENVISAT data. *European Space Agency, (Special Publication) ESA SP*, (SP-636).
- Saich, P., & Borgeaud, M. (2000). Interpreting ERS SAR signatures of agricultural crops in Flevoland, 1993-1996. *IEEE Transactions on Geoscience and Remote Sensing*, 38(2 1), 651–657. <http://doi.org/10.1109/36.841995>
- Schmedtmann, J., & Campagnolo, M. (2015). Reliable Crop Identification with Satellite Imagery in the Context of Common Agriculture Policy Subsidy Control. *Remote Sensing*, 7(7), 9325–9346. <http://doi.org/10.3390/rs70709325>
- Skriver, H. (2007). Signatures of polarimetric parameters and their implications on land cover classification. *IEEE International Geoscience and Remote Sensing Symposium, Barcelona, Spain, July 23-27, 2007*, 4195–4198. <http://doi.org/10.1109/IGARSS.2007.4423775>
- Skriver, H. (2012). Crop classification by multitemporal C- and L-band single- and dual-polarization and fully polarimetric SAR. *IEEE Transactions on Geoscience and Remote Sensing*, 50(6), 2138–2149.
- Susan Moran, M., Alonso, L., Moreno, J. F., Cendrero Mateo, M. P., Fernando De La Cruz, D., & Montoro, A. (2012). A RADARSAT-2 quad-polarized time series for monitoring crop and soil conditions in Barrax, Spain. *IEEE Transactions on Geoscience and Remote Sensing*, 50(4), 1057–1070.
- Swain, P. (1973). Two effective feature selection criteria for multispectral remote sensing. *LARS Technical Note 042673*, (1), 1–6. Retrieved from <http://docs.lib.purdue.edu/larstech/39/>
- Swain, P. H., & Davis, S. M. (1978). *Remote Sensing: The Quantitative Approach*. McGraw-Hill College.
- Tatsumi, K., Yamashiki, Y., Canales Torres, M. A., & Taipe, C. L. R. (2015). Crop classification of upland fields using Random forest of time-series Landsat 7 ETM+ data. *Computers and Electronics in Agriculture*, 115, 171–179. <http://doi.org/10.1016/j.compag.2015.05.001>
- Tso, B., & Mather, P. (2009). *Classification methods in remote sensing data* (2nd ed.). CRC Press, Boca Raton (USA).
- Ulaby, F. T., Moore, R. K., & Fung, A. K. (1986). *Microwave Remote Sensing, Active and Passive. Volume III From Theory to Application*. Retrieved from

http://www.researchgate.net/publication/4704387_Microwave_Remote_Sensing_Active_and_Passive._Volume_III_From_Theory_to_Application

Ulander, L. M. H. (1996). Radiometric slope correction of synthetic-aperture radar images. *IEEE Transactions on Geoscience and Remote Sensing*, 34(5), 1115–1122. <http://doi.org/10.1109/36.536527>

Wang, D., Lin, H., Chen, J., Zhang, Y., & Zeng, Q. (2010). Application of multi-temporal ENVISAT ASAR data to agricultural area mapping in the Pearl River Delta. *International Journal of Remote Sensing*, 31(6), 1555–1572. <http://doi.org/10.1080/01431160903475258>

Waske, B., & Braun, M. (2009). Classifier ensembles for land cover mapping using multitemporal SAR imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 64(5), 450–457. <http://doi.org/10.1016/j.isprsjprs.2009.01.003>

Waske, B., & van der Linden, S. (2008). Classifying Multilevel Imagery From SAR and Optical Sensors by Decision Fusion. *IEEE Transactions on Geoscience and Remote Sensing*, 46(5), 1457–1466. <http://doi.org/10.1109/TGRS.2008.916089>